

SKRIPSI

**PREDIKSI SIFAT MEKANIK ALUMINIUM BERDASARKAN
UNSUR KIMIA PADUAN MENGGUNAKAN MODEL
*MACHINE LEARNING***

*Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Teknik
Pada Program Studi Teknik Mesin Fakultas Teknik Universitas Muhammadiyah
Sumatera Barat*



Oleh:

PRIMA FIERZA SAPUTRA
191000221201050

**PROGRAM STUDI TEKNIK MESIN
FAKULTAS TEKNIK
UNIVERSITAS MUHAMMADIYAH SUMATERA BARAT
2023**

HALAMAN PENGESAHAN

SKRIPSI

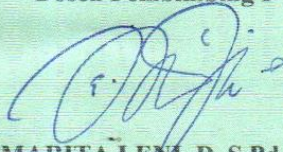
**PREDIKSI SIFAT MEKANIK ALUMINIUM BERDASARKAN
UNSUR KIMIA PADUAN MENGGUNAKAN MODEL
*MACHINE LEARNING***

Oleh:

PRIMA FIERZA SAPUTRA
191000221201050

Disetujui Oleh:

Dosen Pembimbing I



DESMARITA LEMI D. S.Pd., M.T.
NIDN. 1003038503

Dosen Pembimbing II



FEMI EARNESTLY, S.Si., M.Si., Ph.D.
NIDN. 1026127903

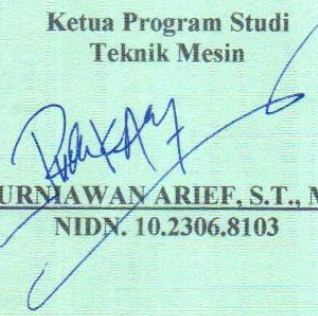
Diketahui Oleh:

Dekan Fakultas Teknik
UM Sumatera Barat




MASRIL, S.T., M.T.
NIDN. 10.0505.7407

Ketua Program Studi
Teknik Mesin


RUDI KURNIAWAN ARIEF, S.T., M.T., Ph.D.
NIDN. 10.2306.8103

LEMBAR PERSETUJUAN TIM PENGUJI

Skripsi ini sudah dipertahankan dan disempurnakan berdasarkan masukan dan koreksi Tim Penguji pada ujian tertutup tanggal .. Juli 2023 di Fakultas Teknik Universitas Muhammadiyah Sumatera Barat.

Bukittinggi, 07 Juli 2023
Mahasiswa,

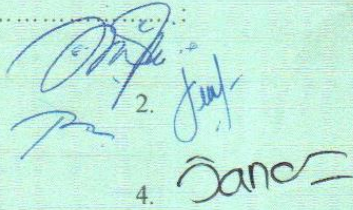


PRIMA FIERZA SAPUTRA
191000221201050

Disetujui Tim Penguji Skripsi tanggal

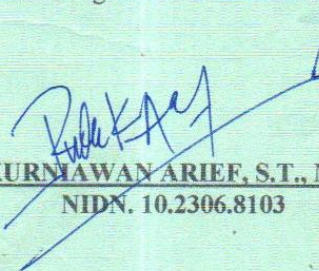
1. Desmarita Leni, D, S.Pd., M.T.
2. Femi Earnestly, S.Si., M.Si., Ph.D.
3. Riza Muharni, S.T., M.T.
4. Jana Hafiza, S.T., M.T.

1.
2.
3.



4.

Mengetahui,
Ketua Program Studi Teknik Mesin



RUDI KURNIAWAN ARIEF, S.T., M.T., Ph.D
NIDN. 10.2306.8103

LEMBAR PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini :

Nama : Prima Fierza Saputra

NIM : 19.10.002.21201.050

Judul Skripsi : Prediksi Sifat Mekanik Aluminium Berdasarkan Unsur Kimia
Paduan Menggunakan Model *Machine Learning*

Menyatakan dengan sebenarnya bahwa penulisan Skripsi ini berdasarkan penelitian, pemikiran dan pemaparan asli dari saya sendiri, baik untuk naskah laporan maupun kegiatan yang tercantum sebagai bagian dari Skripsi ini. Jika terdapat karya orang lain, saya akan mencantumkan sumber yang jelas.

Demikian pernyataan ini saya buat dengan sesungguhnya dan apabila dikemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka saya bersedia menerima sanksi akademik berupa pencabutan gelar yang telah diperoleh karena karya tulis ini dan sanksi lain sesuai dengan peraturan yang berlaku di Universitas Muhammadiyah Sumatera Barat.

Demikian pernyataan ini saya buat dalam keadaan sadar dan tanpa paksaan dari pihak manapun.

Bukittinggi, 07 Juli 2023



PRIMA FIERZA SAPUTRA
191000221201050

ABSTRAK

Studi ini merancang dan membandingkan model *machine learning* optimal untuk memprediksi sifat mekanik aluminium paduan dengan kode 1050 (A91050) berdasarkan komposisi persentase unsur kimia aluminium menggunakan *software rapidminer* dengan algoritma *decision tree* dan *Random Forest*. Tujuannya adalah untuk mengembangkan model prediksi berbasis data yang memiliki akurasi tinggi dalam upaya meminimalisir pengujian fisik pada aluminium dengan berbagai jenis komposisinya. Pemodelan *machine learning* dalam studi ini memiliki sembilan variabel input yang terdiri dari unsur kimia aluminium seperti Al, Mg, Zn, Ti, Cu, Mn, Cr, Fe, Si, dan dua variabel output atau target yang terdiri dari YS dan TS. Selain itu, *Heatmap correlation* digunakan untuk mengamati korelasi antara unsur-unsur kimia dan sifat mekanik aluminium paduan. Perbandingan dari algoritma-algoritma ini menunjukkan bahwa *Random Forest* (RF) memiliki performa lebih baik daripada algoritma lain dalam memprediksi YS dengan MAE sebesar 7,157, RMSE sebesar 11,248, dan nilai SC sebesar 0,977. Di sisi lain, *Random Forest* (RF) juga memiliki performa lebih baik dalam memprediksi TS dengan MAE sebesar 29,296, RMSE sebesar 42,382, dan nilai SC sebesar 0,443.

Kata kunci: *Machine learning, Rapidminer, Aluminium, Algoritma, Tensile strength, Yield strength*

ABSTRACT

This study designs and compares optimal machine learning models for predicting the mechanical properties of alloyed aluminum with code 1050 (A91050) based on the percentage composition of chemical elements using the software RapidMiner with decision tree and Random Forest algorithms. The aim is to develop a data-driven predictive model with high accuracy to minimize the need for physical testing on aluminum with various compositional variations. The machine learning modeling in this study involves nine input variables, comprising chemical elements such as Al, Mg, Zn, Ti, Cu, Mn, Cr, Fe, Si, and two output or target variables, YS and TS (yield strength and tensile strength). Additionally, a Heatmap correlation is employed to observe the correlations between the chemical elements and the mechanical properties of the alloyed aluminum. The comparison of these algorithms reveals that Random Forest (RF) outperforms other algorithms in predicting YS with a Mean Absolute Error (MAE) of 7.157, Root Mean Square Error (RMSE) of 11.248, and a coefficient of determination (SC) of 0.977. On the other hand, Random Forest (RF) also exhibits better performance in predicting TS with an MAE of 29.296, RMSE of 42.382, and SC value of 0.443.

Keywords: Machine learning, Rapidminer, Aluminium, Algorithm, Tensile strength, Yield strength

KATA PENGANTAR

Puji syukur kepada Allah SWT atas segala berkat yang telah diberikan-Nya, sehingga skripsi ini dapat penulis selesaikan dengan tepat waktu. Skripsi ini merupakan salah satu kewajiban yang harus diselesaikan untuk memenuhi sebagian persyaratan akademik untuk memperoleh gelar Sarjana Teknik Mesin di Universitas Muhammadiyah Sumatera Barat (UM Sumatera Barat).

Penulis menyadari bahwa tanpa bimbingan, bantuan, dan do'a dari berbagai pihak, Laporan Skripsi ini tidak akan dapat diselesaikan tepat pada waktunya. Oleh karena itu, penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah membantu dalam proses pengerjaan Skripsi ini. Ucapan terima kasih ini penulis tuju kepada:

1. Bapak **Masril, S.T, M.T** selaku dekan Fakultas Teknik UM Sumatera Barat,
2. Bapak **Rudi Kurniawan Arief, S.T, M.T, Ph. D** selaku Ketua Prodi Teknik Mesin,
3. Ibuk **Desmarita Leni. D, S.Pd., M.T.** selaku Dosen Pembimbing I skripsi yang telah memberikan bimbingan dan banyak memberikan masukan kepada penulis,
4. Ibuk **Femi Earnestly, S.Si., M.Si., Ph.D.** selaku Dosen Pembimbing II skripsi yang telah memberikan bimbingan dan banyak memberikan masukan kepada penulis,
5. Dan yang paling penting terima kasih untuk diri sendiri yang sudah mampu bertahan sejauh ini,
6. Ibu, Ayah, adek dan kawan-kawan serta seluruh keluarga lain yang selalu mensupport penulis sampai dititik ini,
7. Senior, sahabat dan rekan-rekan Mahasiswa jurusan Teknik Mesin Universitas Muhammadiyah Sumatera Barat atas semangat, kritikan, dan masukan-masukan yang membangun.

Akhir kata penulis menyadari bahwa masih terdapat banyak kekurangan dalam skripsi ini. Oleh karena itu, saran dari pembaca akan sangat bermanfaat bagi penulis. Semoga skripsi ini dapat bermanfaat bagi semua pihak yang membacanya. Khususnya mahasiswa teknik mesin.

Bukittinggi, 07 Juli 2023

Penulis



DAFTAR ISI

Halaman

HALAMAN JUDUL

HALAMAN PENGESAHAN

LEMBARAN PERSETUJUAN TIM PENGUJI

HALAMAN PERNYATAAN KEASLIAN SKRIPSI

ABSTRAK

KATA PENGANTAR	i
DAFTAR ISI	iii
DAFTAR TABEL	vii
DAFTAR GAMBAR	v
DAFTAR LAMPIRAN	vi

BAB I PENDAHULUAN

1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian dan Manfaat Penelitian	4
1.4.1 Tujuan Penelitian.....	4
1.4.2 Manfaat Penelitian.....	5
1.5 Sistematika Penulisan	5

BAB II TINJAUAN PUSTAKA

2.1 Aluminium.....	6
2.1.1 Sifat Mekanik Aluminium.....	7
2.2 Database Material	15
2.3 <i>Machine Learning</i>	17
2.3.1 <i>Decision Tree</i>	19
2.3.2 <i>Random Forest</i>	21
2.4 <i>Rapid Miner</i>	22
2.5 <i>Dataset</i>	24

BAB III	METODOLOGI PENELITIAN	27
	3.1 Diagram Alir Penelitian	27
	3.2 Tempat dan Waktu Penelitian.....	27
	3.3 Alat dan Bahan	28
	3.4 Metode Penelitian	29
BAB IV	DATA dan PEMBAHASAN.....	33
	4.1 Data.....	33
	4.1.1 Pemodelan <i>machine learning</i>	35
	4.2 Pembahasan	40
	4.2.1 <i>Cross validation</i>	40
	4.2.2 Evaluasi model	43
BAB V	KESIMPULAN dan SARAN	47
	5.1 Kesimpulan.....	47
	5.2 Saran	47
DAFTAR PUSTAKA		
DAFTAR LAMPIRAN		



DAFTAR TABEL

No Tabel	Halaman
Tabel 4.1. Statistik dataset aluminium	33
Tabel 4.2. Pengaturan parameter untuk mencari algoritma terbaik.....	35
Tabel 4.3. Perbandingan hasil uji variasi nilai <i>maksimum of depth</i> algoritma <i>decision tree</i> rasio 60:40	36
Tabel 4.4. Perbandingan hasil uji variasi nilai <i>maksimum of depth</i> algoritma <i>random forest</i> rasio 60:40	37
Tabel 4.5. Perbandingan hasil uji variasi nilai <i>number of trees</i> algoritma <i>random forest</i>	39
Tabel 4.6. Hasil Perbandingan nilai metrik validasi pada variasi rasio untuk prediksi <i>tensile strength</i>	41
Tabel 4.7. Hasil Perbandingan nilai metrik validasi pada variasi rasio untuk prediksi <i>yield strength</i>	42



DAFTAR GAMBAR

No Gambar		Halaman
Gambar 2.1.	Aluminium.....	6
Gambar 2.2.	Unsur kimia aluminium.....	8
Gambar 2.3.	Salah satu contoh ikatan unsur kimia aluminium dengan unsur kimia klorida yang membentuk senyawa	8
Gambar 2.4.	Kurva tegangan dan regangan	10
Gambar 2.5.	Rangka mobil yang terbuat dari aluminium	12
Gambar 2.6.	Kurva pengujian <i>Yield Strength</i> dan <i>Tensile Strength</i> AA6016 T4 aluminium alloy sheet	14
Gambar 2.7.	Referensi Database material untuk material aluminium dari website <i>makeitfrom.com</i>	15
Gambar 2.8.	Ilustrasi skema cara kerja machine learning.....	18
Gambar 2.9.	Model <i>Decision Tree</i>	19
Gambar 2.10.	Model <i>Random Forest</i>	21
Gambar 2.11.	Tampilan <i>software RapidMiner</i>	23
Gambar 2.12.	Dataset	25
Gambar 3.1.	Diagram alir penelitian.....	27
Gambar 3.2.	Ilustrasi set pelatihan (orange) dan pengujian (biru) untuk $k = 5$	31
Gambar 4.1.	<i>Heatmap correlation</i>	34
Gambar 4.2.	Grafik perbandingan hasil uji variasi nilai <i>maksimum of depth</i> algoritma <i>decision tree</i>	37
Gambar 4.3.	Grafik perbandingan hasil uji variasi nilai <i>maksimum of depth</i> algoritma <i>random forest</i>	38
Gambar 4.4.	Grafik perbandingan hasil uji variasi nilai <i>number of trees</i> algoritma <i>random forest</i>	40
Gambar 4.5.	Perbandingan performa algoritma <i>random forest</i> dan <i>decision tree</i> pada prediksi TS	41
Gambar 4.6.	Perbandingan performa algoritma <i>random forest</i> dan <i>decision tree</i> pada prediksi YS.....	42

- Gambar 4.7. Grafik perbandingan data prediksi nilai *tensile strength* dengan data aktual menggunakan algoritma *Random forest* rasio 70:30 43
- Gambar 4.8. Grafik perbandingan data prediksi nilai *tensile strength* dengan data aktual menggunakan algoritma *Decision tree* rasio 70:30 44
- Gambar 4.9. Grafik perbandingan data prediksi nilai *yield strength* dengan data aktual menggunakan algoritma *Random forest* rasio 70:30 45
- Gambar 4.10. Grafik perbandingan data prediksi nilai *yield strength* dengan data aktual menggunakan algoritma *Decision tree* rasio 70:30 45



DAFTAR LAMPIRAN

Lampiran 1. *Database aluminium alloys* dari website *MakeItFrom.com*



BAB I

PENDAHULUAN

1.1 Latar Belakang

Aluminium merupakan salah satu material yang paling sering digunakan dalam berbagai industri karena memiliki berbagai keunggulan seperti ringan, tahan korosi, dan mudah diolah[1]. Pengolahan aluminium dilakukan dengan pengecoran dan terbagi menjadi 2 yaitu aluminium murni dan aluminium paduan. Perbedaannya terletak pada konsentrasi aluminiumnya misal aluminium murni bisa memiliki kandungan aluminium sampai dengan 90% dan dipadu dengan material lain untuk menambah kekuatan mekaniknya. Sedangkan pada aluminium paduan komposisi logam paduan bisa jadi besar pada aluminium itu sendiri[2]. Salah satu faktor yang mempengaruhi sifat mekanik dari aluminium adalah komposisi kimia, kekuatan mekanik pada aluminium dapat ditingkatkan dengan penambahan unsur padu seperti Cu, Mg, Zn, Mn, V, Fe, Si dan Ni.

Terdapat beberapa jenis pengujian mekanis untuk menentukan sifat mekanik aluminium, diantaranya meliputi pengujian tarik (*tensile test*), pengujian kekerasan (*hardness test*), pengujian impak (*impact test*) dan pengujian mekanik lanjut meliputi pengujian fatik (*fatigue test*), pengujian mulur (*creep test*), pengujian fraktur (*fracture test*), dan pengujian keausan (*wear test*)[3]. Tujuan uji mekanis pada material adalah untuk mengukur sifat-sifat mekanis dari material tersebut, seperti kekuatan, kekakuan, ketahanan, dan elastisitas. Dengan menguji sifat mekanis dari material, kita dapat menentukan apakah material tersebut cocok atau tidak digunakan dalam aplikasi tertentu. Misalnya, jika material diuji dan ditemukan tidak cukup kuat, maka material tersebut tidak dapat digunakan dalam aplikasi yang membutuhkan kekuatan tinggi. uji mekanis juga dapat digunakan untuk membandingkan sifat mekanis dari beberapa jenis material yang berbeda, sehingga dapat membantu dalam memilih material yang paling cocok untuk aplikasi tertentu sesuai dengan manfaat dan kegunaannya. Pengujian mekanis ini tentunya memakan banyak biaya dan waktu sehingga mengurangi keefisienan dalam proses manufaktur.

Dalam perkembangan yang pesat dari kecerdasan buatan (AI), khususnya machine learning, banyak penelitian yang memanfaatkan data untuk mengurangi pengujian secara fisik dan meningkatkan efisiensi dan efektivitas dalam berbagai bidang. Salah satu cara yang digunakan untuk mengolah data dan menganalisis informasi dari berbagai sumber adalah melalui platform analytics seperti *RapidMiner*, *Weka*, *SAS*, *Alteryx*, *KNIME*, dan *Python*. Dengan platform *analytics* tersebut, para peneliti dapat memproses data besar dan menghasilkan informasi yang lebih akurat, serta memprediksi kemungkinan hasil berbagai situasi dan masalah. Hal ini membuka peluang baru untuk inovasi dan kemajuan dalam bidang-bidang seperti manufaktur, kesehatan, keuangan, dan lain-lain. Penelitian oleh Stefanus pada tahun 2021 menunjukkan bahwa proses rekayasa sangat membutuhkan peran komputasi untuk memperoleh akurasi dan kehandalan yang tinggi. Kompetisi yang ketat di dunia industri menuntut siklus desain yang pendek yang didasarkan pada simulasi numerik untuk mengurangi pengujian prototipe secara fisik dan dapat memprediksi proses pengujian dengan data yang telah dihasilkan dari pengujian sebelumnya[4]. Komputasi *engineering* juga diterapkan pada ilmu material, dan ada beberapa referensi yang menyebutkan penggunaan teknologi berbasis kecerdasan buatan di bidang pengolahan dan rekayasa logam. David dalam penelitiannya tentang Prediksi kurva tegangan-regang bilinear paduan aluminium menggunakan kecerdasan buatan dan big data juga menerapkan komputasi *engineering*[5].

Perkembangan teknologi industri yang pesat harus diiringi dengan evaluasi sifat-sifat berbagai bahan logam yang digunakan dalam konstruksi untuk memastikan keberhasilan produk dan mengurangi kemungkinan terjadinya kegagalan. Model berbasis data dapat menjadi alternatif yang lebih efisien karena tidak memerlukan pengujian fisik langsung yang memakan waktu lama, mahal, dan tidak ramah lingkungan.

Desmarita leni dkk (2022), dalam penelitian dengan judul “Perbandingan Algoritma Machine Learning Untuk Prediksi Sifat Mekanik Pada Baja Paduan Rendah” meneliti tentang prediksi sifat mekanik baja paduan rendah menggunakan *machine learning*. Studi ini membandingkan tiga algoritma, yaitu pohon keputusan (*decision tree/DT*), hutan acak (*random forest/RF*), dan jaringan saraf tiruan

(*artificial neural network/ANN*), di mana algoritma ANN memiliki performa yang lebih baik dengan menghasilkan nilai RMSE sebesar 6,187 dengan pengaturan parameter siklus pelatihan 30.000, tingkat pembelajaran 0.007, momentum 0.9, dan ukuran lapisan tersembunyi sebanyak 9[6].

Pada penelitian D. Merayo dkk (2020) dengan judul “*Prediction of Physical and Mechanical Properties for Metallic Materials Selection Using Big Data and Artificial Neural Networks*”, hasil studi menunjukkan sebuah jaringan saraf tiruan (ANN) dibangun dengan ribuan perceptron, topologi dan koneksi ANN telah dioptimalkan untuk mempercepat pelatihan dan kapasitas prediktif ANN. Setelah pelatihan yang sesuai, sistem mampu membuat prediksi tentang densitas material dan modulus Young dengan kepercayaan rata-rata lebih dari 99% dan 98%, masing-masing[5].

Dalam penelitian Ankit Agrawal dkk (2014) dengan judul “*Exploration of data science techniques to predict fatigue strength of steel from composition and processing parameters*”, hasil studi menunjukkan keberhasilan mendemonstrasikan kegunaan alat penambangan data seperti ini untuk merangking komposisi dan parameter proses sesuai potensi mereka dalam memprediksi kekuatan kelelahan baja, dan benar-benar mengembangkan model prediktif untuk hal yang sama[7].

Dalam penelitian Samir Kendale dkk (2018) dengan judul “*Supervised Machine-learning Predictive Analytics for Prediction of Postinduction Hypotension*” hasil studi menunjukkan Dari 13.323 kasus, 1.185 (8,9%) mengalami hipotensi pasca induksi. Area di bawah kurva karakteristik operasi penerima menggunakan regresi logistik adalah 0,71 (95% CI, 0,70 hingga 0,72), mesin vektor pendukung adalah 0,63 (95% CI, 0,58 hingga 0,60), naive Bayes adalah 0,69 (95% CI, 0,67 hingga 0,69), tetangga terdekat k adalah 0,64 (95% CI, 0,63 hingga 0,65), analisis diskriminan linear adalah 0,72 (95% CI, 0,71 hingga 0,73), hutan acak adalah 0,74 (95% CI, 0,73 hingga 0,75), jaringan saraf tiruan adalah 0,71 (95% CI, 0,69 hingga 0,71), dan mesin penguat gradien adalah 0,76 (95% CI, 0,75 hingga 0,77). Area set uji untuk mesin penguat gradien adalah 0,74 (95% CI, 0,72 hingga 0,77). Keberhasilan teknik ini dalam memprediksi hipotensi pasca induksi menunjukkan kelayakan model pembelajaran mesin untuk analitik prediktif dalam

bidang anesthesiologi, dengan kinerja tergantung pada pemilihan model dan penyetelan yang sesuai[8].

Penelitian ini bertujuan merancang sebuah pemodelan dengan *machine learning* menggunakan software *rapid miner* dengan algoritma *decision Random Forest*. Tujuannya adalah untuk mengembangkan model prediksi berbasis data yang memiliki akurasi tinggi dalam upaya meminimalisir pengujian fisik pada aluminium dengan berbagai jenis komposisinya.

1.2 Rumusan Masalah

Berdasarkan latar belakang dan permasalahan dapat ditarik rumusan masalah sebagai berikut:

1. Bagaimana pengaruh unsur kimia paduan aluminium terhadap *Yield Strength* (YS) dan *Tensile Strength* (TS)?
2. Merancang pemodelan *machine learning* untuk memprediksi sifat mekanik aluminium berdasarkan unsur kimia paduan.
3. Bagaimana cara mengevaluasi pemodelan *machine learning* dalam memprediksi sifat mekanik aluminium?

1.3 Batasan Masalah

Pada penelitian ini dibatasi hanya untuk menghitung nilai Sifat mekanik (*yield strength* dan *tensile strength*) pada aluminium paduan dengan kode 1050 (A91050). Dalam penelitian ini algoritma yang digunakan adalah *Random Forest* dan *Decision tree*.

1.4 Tujuan Penelitian dan Manfaat Penelitian

1.4.1 Tujuan penelitian

Tujuan Penelitian ini bertujuan merancang sebuah pemodelan dengan *machine learning* menggunakan aplikasi *rapidminer* dengan tujuan mengembangkan model prediksi berbasis data yang memiliki akurasi tinggi dalam upaya meminimalisir pengujian fisik pada aluminium dengan berbagai jenis komposisinya.

1.4.2 Manfaat penelitian

Manfaat dari penelitian yang dilakukan, yaitu:

1. Dapat membangun sebuah model algoritma pada *machine learning* yang dapat memprediksi sifat mekanik baja paduan rendah secara efektif dan akurat berdasarkan komposisi aluminium.
2. Mengatasi kelemahan pada pengujian fisik secara langsung yang meliputi masalah lingkungan, waktu, biaya, keahlian, dan ketelitian dalam pengujiannya.

1.5 Sistematika Penulisan

Sistematika penulisan laporan skripsi adalah sebagai berikut:

BAB I : PENDAHULUAN

Pada bab I ini terdiri dari latar belakang, maksud dan tujuan, Batasan masalah dan sistematika penulisan.

BAB II : TINJAUAN PUSTAKA

Pada bab II ini dibahas mengenai teori-teori yang berkaitan dengan penelitian yang akan dilakukan.

BAB III : METODOLOGI PENELITIAN

Pada bab III ini berisi mengenai rancangan dari penelitian yang dilakukan, metode dan langkah-langkah dalam penelitian.

BAB IV : DATA DAN ANALISA

Pada bab IV ini berisi tentang data hasil analisis algoritma *machine learning* serta pembahasannya.


BAB V : PENUTUP

Pada bab V ini berisi kesimpulan tentang data-data yang diperoleh, serta diberikan saran sebagai penunjang pengembangan selanjutnya.

BAB II TINJAUAN PUSTAKA

2.1 Aluminium

Aluminium diambil dari bahasa Latin: alumen, alum. Orang-orang Yunani dan Romawi kuno menggunakan aluminium sebagai cairan penutup pori-pori dan bahan penajam proses pewarnaan. Pada tahun 1787, Lavoisier menduga bahwa unsur ini adalah Oksida logam yang belum ditemukan. Pada tahun 1761, de Morveau mengajukan nama alumine untuk basa alum. Pada Tahun 1827, Wohler disebut sebagai ilmuwan yang berhasil mengisolasi logam ini. Pada 1807, Davy memberikan proposal untuk menamakan logam ini Aluminum, walau pada akhirnya setuju untuk menggantinya dengan Aluminium. Nama yang terakhir ini sama dengan nama banyak unsur lainnya yang berakhir dengan “ium”[9]. Berikut bentuk material aluminium yang dapat dilihat pada Gambar 2.1.



Gambar 2.1 Aluminium[10]

Aluminium ditemukan pada tahun 1825 oleh Hans Christian Oersted. Baru diakui secara pasti oleh F. Wohler pada tahun 1827. Sumber unsur ini tidak terdapat bebas, bijih utamanya adalah bauksit. Penggunaan Aluminium antara lain untuk pembuatan kabel, kerangka kapal terbang, mobil dan berbagai produk peralatan rumah tangga. Senyawanya dapat digunakan sebagai obat, penjernih air, fotografi serta sebagai ramuan cat, bahan pewarna, ampelas dan permata sintesis. Aluminium murni adalah logam yang lunak, tahan lama, ringan, dan dapat ditempa dengan penampilan luar bervariasi antara keperakan hingga abu-abu, tergantung kekasaran

permukaannya. Kekuatan tarik Aluminium murni adalah 90 MPa, sedangkan aluminium paduan memiliki kekuatan Tarik berkisar hingga 600 MPa[11]. Aluminium memiliki berat sekitar satu pertiga baja, mudah ditebuk, diperlakukan dengan mesin, dicor, ditarik (drawing), dan diekstrusi[12].

Klasifikasi penggolongan aluminium terbagi menjadi 2 yaitu:

1. Aluminium Murni

Aluminium 99% tanpa tambahan logam paduan apapun dan dicetak dalam keadaan biasa, hanya memiliki kekuatan tensil sebesar 90 MPa, terlalu lunak untuk penggunaan yang luas sehingga seringkali aluminium dipadukan dengan logam lain.

2. Aluminium Paduan


Elemen paduan yang umum digunakan pada aluminium adalah silikon, magnesium, tembaga, seng, mangan, dan juga lithium sebelum tahun 1970. Secara umum, penambahan logam paduan hingga konsentrasi tertentu akan meningkatkan kekuatan tensil dan kekerasan, serta menurunkan titik lebur. Jika melebihi konsentrasi tersebut, umumnya titik lebur akan naik disertai meningkatnya kerapuhan akibat terbentuknya senyawa, kristal, atau granula dalam logam. Kelemahan aluminium paduan adalah pada ketahanannya terhadap lelah (*fatigue*). Aluminium paduan tidak memiliki batas lelah yang dapat diperkirakan seperti baja, yang berarti failure akibat *fatigue* dapat muncul dengan tiba-tiba bahkan pada beban siklik yang kecil[13].

2.1.1 Sifat Mekanik Aluminium

A. Unsur Kimia

Aluminium ialah unsur kimia. Lambang aluminium ialah Al (Bahasa Latin: Aluminium), dan nomor atomnya 13. Aluminium ialah logam paling berlimpah. Aluminium bukan merupakan jenis logam berat, tetapi merupakan elemen yang berjumlah sekitar 8% dari permukaan bumi dan paling berlimpah ketiga. Aluminium terdapat dalam penggunaan aditif makanan, antasida, *buffered aspirin*, *astringents*, semprotan hidung, antiperspirant, air minum, knalpot mobil, asap tembakau, penggunaan aluminium foil, peralatan masak, kaleng, keramik, dan

kembang api. Berikut adalah gambar unsur dan ikatan molekul aluminium yang dapat dilihat pada Gambar 2.2 dan Gambar 2.3.



Gambar 2.2 Unsur kimia aluminium[10]



Gambar 2.3 Salah satu contoh ikatan unsur kimia aluminium dengan unsur kimia klorida yang membentuk senyawa[10]

Resistensi terhadap korosi terjadi akibat fenomena pasivasi, yaitu terbentuknya lapisan aluminium oksida ketika aluminium terpapar dengan udara bebas[14].

Lapisan aluminium oksida ini mencegah terjadinya oksidasi lebih jauh. Dalam keadaan murni aluminium terlalu lunak, terutama kekuatannya sangat rendah untuk dapat dipergunakan pada berbagai keperluan teknik. Dengan pemaduan ini dapat diperbaiki jenis dan pengaruh unsur-unsur paduan terhadap perbaikan sifat aluminium antara lain:

1. Silikon (Si)

Dengan atau tanpa paduan lainnya silikon mempunyai ketahanan terhadap korosi. Bila bersama aluminium ia akan mempunyai kekuatan yang tinggi

setelah perlakuan panas, tetapi silikon mempunyai kualitas pengerjaan mesin yang jelek, selain itu juga mempunyai ketahanan koefisien panas yang rendah.

2. Tembaga (Cu)

Dengan unsur tembaga pada aluminium akan meningkatkan kekerasannya dan kekuatannya karena tembaga bisa memperhalus struktur butir dan akan mempunyai kualitas pengerjaan mesin yang baik, mampu tempa, keuletan yang baik dan mudah dibentuk.

3. Magnesium (Mg)

Dengan unsur magnesium pada aluminium akan mempunyai ketahanan korosi yang baik dan kualitas pengerjaan mesin yang baik, mampu las serta kekuatannya cukup.

4. Nikel (Ni)

Dengan unsur nikel aluminium dapat bekerja pada temperatur tinggi, misalnya piston dan silinder head untuk motor.

5. Mangan (Mn)

Dengan unsur mangan aluminium sangat mudah dibentuk, tahan korosi baik, sifat dan mampu lasnya baik.

6. Seng (Zn)

Umumnya seng ditambahkan bersama-sama dengan unsur tembaga dalam prosentase kecil.

7. Ferro (Fe)


Penambahan ferro dimaksud untuk mengurangi penyusutan, tapi penambahan ferro (Fe) yang besar akan menyebabkan struktur perubahan butir yang kasar namun hal ini dapat diperbaiki dengan Mg atau Cr.

8. Titanium (Ti)

Penambahan titanium pada aluminium dimaksud untuk mendapat struktur butir yang halus. Biasanya penambahan bersama-sama dengan Cr dalam prosentase 0,1%, titanium juga dapat meningkatkan mampu mesin.

B. Sifat Mekanik Aluminium

Aluminium merupakan material yang sangat diandalkan dalam berbagai aplikasi industri, termasuk dalam bidang teknik mesin. Hal ini tidak terlepas dari sifat mekaniknya yang jauh lebih baik dari baja paduan lainnya, untuk mengetahui sifat mekanik aluminium biasanya diuji dengan mesin uji tarik, dimana hasilnya dapat dilihat dari kurva tegangan dan regangan seperti yang terlihat pada Gambar 2.4.



Gambar 2.4 Kurva tegangan dan regangan[15]

Sifat-sifat mekanik aluminium seperti *yield strength* (YS), *ultimate tensile strength* (UTS), *elongation* (EL), dan *reduction area* (RA) memiliki peranan krusial dalam menentukan performa aluminium.

a. *Yield strength* (YS)

Yield strength adalah tegangan maksimum yang dapat ditahan oleh sebuah material sebelum mengalami perubahan permanen atau deformasi plastis. Sifat ini menunjukkan batas kekuatan material saat terjadi deformasi awal. Pengetahuan tentang *yield strength* aluminium sangat penting dalam mendesain struktur dan komponen mesin yang mampu menahan beban dan tegangan yang diberikan. YS dapat dihitung menggunakan persamaan 2.1[16].

$$YS = F_y / A_0 \dots \dots \dots (2.1)$$

Dimana :

F_y adalah tegangan batas elastis dan A_0 adalah luas penampang awal.

b. *Ultimate tensile strength (UTS)*

Ultimate tensile strength adalah tegangan maksimum yang dapat ditahan oleh sebuah material sebelum mengalami kegagalan atau patah. Sifat ini mengindikasikan batas kekuatan maksimum aluminium. UTS penting dalam menentukan kekuatan material saat menghadapi beban tarik maksimum dalam aplikasi teknik mesin. UTS dapat dihitung menggunakan persamaan 2.2[16].

$$UTS = F_u / A_0 \dots \dots \dots (2.2)$$

Dimana :

F_u adalah tegangan maksimum dan A_0 adalah luas penampang awal.

c. *Elongation (EL)*

Elongation adalah persentase perubahan panjang material saat terjadi pengujian tarik hingga material patah. Sifat ini menggambarkan seberapa plastis material dapat mengalami deformasi sebelum patah. *Elongation* memberikan informasi tentang kelenturan dan keuletan aluminium dalam menghadapi beban yang mengakibatkan perubahan bentuk. EL dapat dihitung menggunakan persamaan 2.3[17].

$$EL = (L - L_0) / L_0 \times 100\% \dots \dots \dots (2.3)$$

Dimana :

L adalah panjang bahan setelah diuji tarik, L_0 adalah panjang bahan sebelum diuji Tarik

d. *Reduction area (RA)*

Reduction area adalah persentase penurunan luas penampang material setelah pengujian tarik. Sifat ini menunjukkan kemampuan aluminium dalam menyerap energi deformasi sebelum patah. *Reduction area* juga menggambarkan keuletan material dalam menghadapi beban yang menyebabkan perubahan bentuk. RA dapat dihitung menggunakan persamaan 2.4[17].

$$RA = (A_0 - A) / A_0 \times 100\% \dots \dots \dots (2.4)$$

Dimana :

A₀ adalah luas penampang awal bahan, dan A adalah luas penampang bahan setelah diuji tarik.

Pentingnya sifat-sifat mekanik ini dalam aplikasi teknik mesin adalah untuk memastikan keandalan, kekuatan, kelenturan, dan keuletan aluminium dalam kondisi operasional yang beragam.

Kebutuhan produk manufaktur terhadap aluminium sangatlah tinggi. Aluminium merupakan logam yang ringan, kuat, tahan korosi, dan memiliki konduktivitas panas dan listrik yang baik. Keunggulan ini membuat aluminium menjadi bahan pilihan dalam berbagai industri, termasuk otomotif, pesawat terbang, konstruksi, elektronik, dan kemasan.

Salah satu contoh penggunaan aluminium dalam industri manufaktur adalah pada industri otomotif. Aluminium digunakan dalam pembuatan bodi kendaraan untuk mengurangi berat dan meningkatkan efisiensi bahan bakar. Dengan menggunakan aluminium, mobil dapat menjadi lebih ringan dan memiliki performa yang lebih baik. Selain itu, aluminium juga digunakan dalam pembuatan mesin dan bagian lainnya, seperti transmisi, suspensi, dan sistem pendingin. Pada gambar 2.5 dibawah merupakan penampakan kerangka mobil yang terbuat dari aluminium.



Gambar 2.5 Rangka mobil yang terbuat dari aluminium[18]

Contoh lainnya adalah dalam industri pesawat terbang. Aluminium digunakan dalam pembuatan badan pesawat dan komponen strukturalnya. Kekuatan dan keuletan aluminium membuatnya cocok untuk digunakan dalam pesawat, yang harus dapat menahan tekanan dan kecepatan tinggi. Selain itu, aluminium juga digunakan dalam sistem penghantaran listrik dan pendingin di dalam pesawat.

Secara keseluruhan, aluminium memiliki peran penting dalam industri manufaktur. Keunggulannya dalam hal kekuatan, ringan, dan ketahanan terhadap korosi membuatnya menjadi bahan pilihan dalam berbagai aplikasi, mulai dari mobil dan pesawat terbang hingga berbagai peralatan elektronik dan kemasan. Dengan perkembangan teknologi dan permintaan yang terus meningkat, kebutuhan produk manufaktur terhadap aluminium diperkirakan akan terus tumbuh di masa mendatang.

C. *Yield Strength* (YS) dan *Tensile Strength* (TS) aluminium

Yield Strength (YS) dan *Tensile Strength* (TS) adalah dua sifat mekanik penting yang digunakan untuk menggambarkan kekuatan material, termasuk aluminium.

1. *Yield Strength* (YS)

Yield Strength (YS) adalah tingkat tegangan maksimum yang dapat ditahan oleh sebuah bahan sebelum mengalami perubahan permanen atau deformasi plastis. Dalam hal aluminium, *Yield Strength* mengacu pada tegangan di mana aluminium mulai mengalami deformasi permanen atau terjadi perubahan struktural pada kristal aluminium. Ketika tegangan yang diterapkan melebihi *Yield Strength*, aluminium akan mengalami pemanjangan atau perubahan bentuk permanen. Nilai *Yield Strength* umumnya dinyatakan dalam satuan tekanan, seperti megapascal (MPa) atau pound per inci persegi (psi).

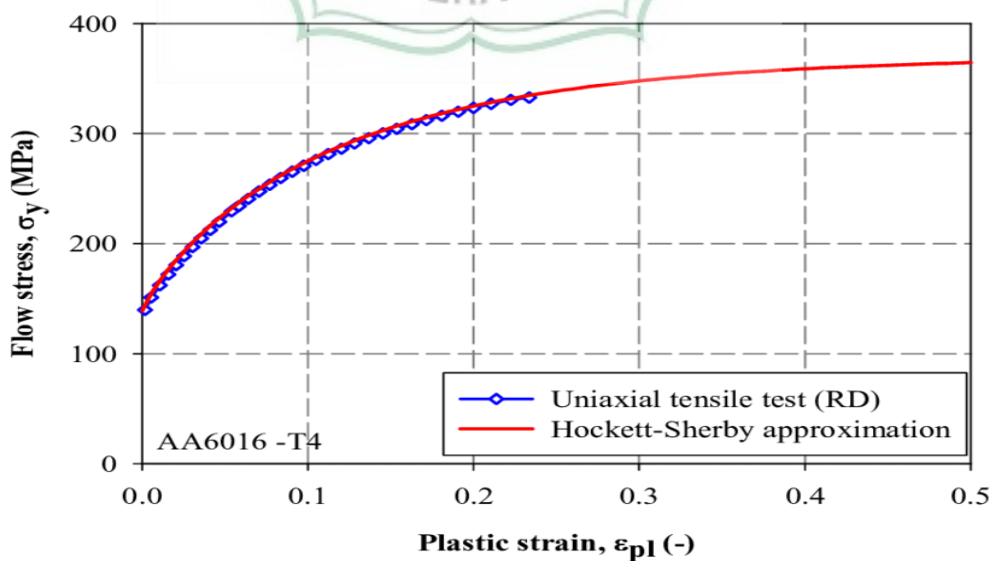
2. *Tensile Strength* (TS):

Tensile Strength (TS), juga dikenal sebagai *Ultimate Tensile Strength* (UTS), adalah tingkat tegangan maksimum yang dapat ditahan oleh sebuah bahan sebelum patah atau pecah. Pada saat TS tercapai, bahan akan mengalami pemisahan atau patah karena tegangan yang diterapkan. Nilai *Tensile*

Strength umumnya dinyatakan dalam satuan tekanan, seperti megapascal (MPa) atau pound per inci persegi (psi).

Ketika mengevaluasi aluminium, baik *Yield Strength* maupun *Tensile Strength* penting untuk memahami kekuatan dan kegunaannya dalam aplikasi tertentu. Aluminium umumnya memiliki *Yield Strength* yang lebih rendah dibandingkan dengan baja, tetapi memiliki *Tensile Strength* yang lebih tinggi. Hal ini membuat aluminium cocok untuk digunakan dalam berbagai aplikasi di mana kekuatan ringan dan kekuatan khusus dibutuhkan, seperti industri otomotif, pesawat terbang, konstruksi bangunan, dan lain sebagainya.

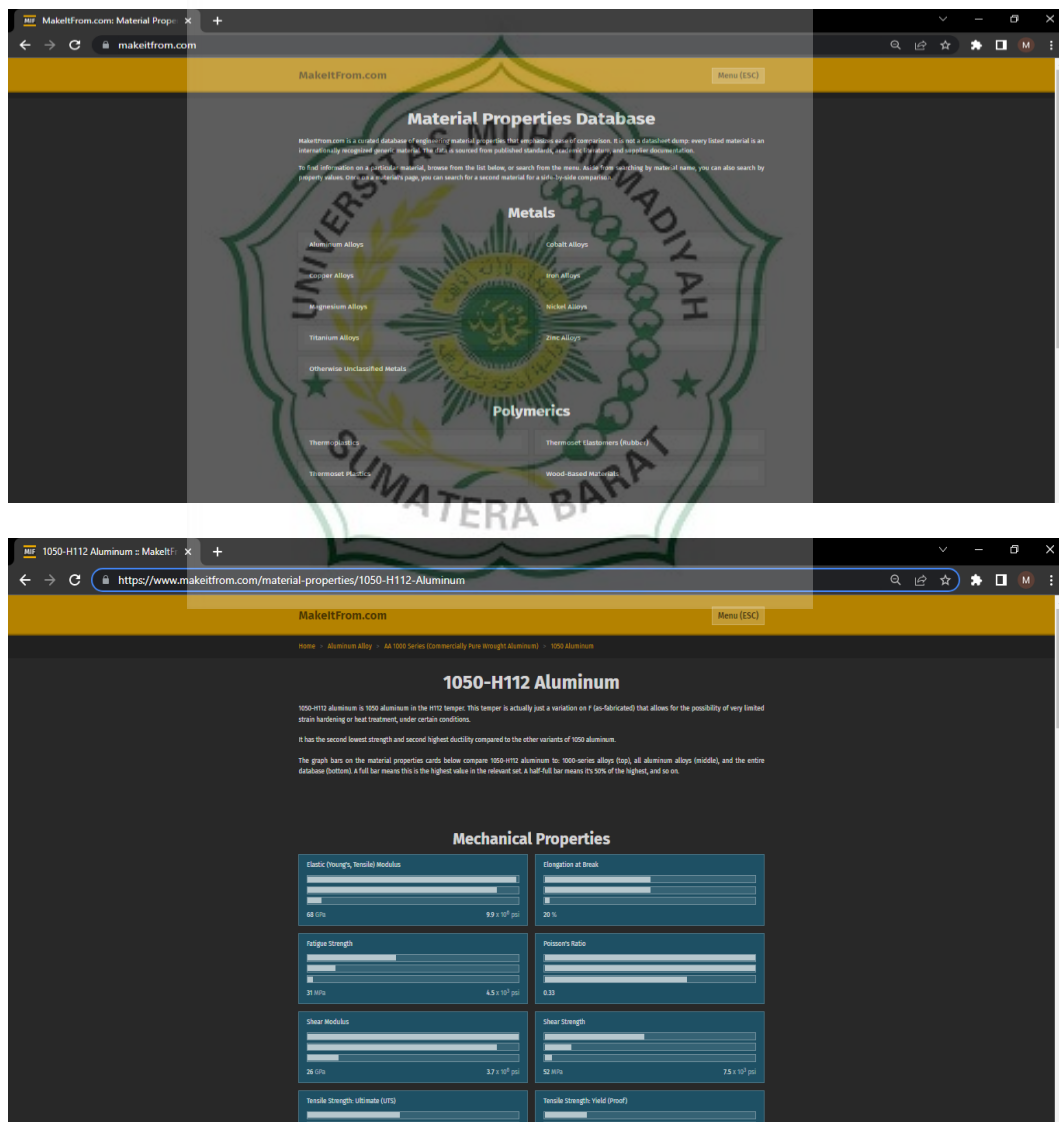
Perlu diperhatikan bahwa *Yield Strength* dan *Tensile Strength* merupakan sifat mekanik yang bergantung pada komposisi dan kondisi aluminium. Nilai-nilai tersebut dapat bervariasi tergantung pada jenis paduan aluminium[19], perlakuan panas, dan proses manufaktur yang digunakan dalam produksi bahan aluminium tersebut[20]. Oleh karena itu, spesifikasi teknis atau lembar data material aluminium akan memberikan informasi yang lebih spesifik mengenai *Yield Strength* dan *Tensile Strength* untuk jenis aluminium tertentu. Pada Gambar 2.6 dibawah ini merupakan salah satu kurva pengujian *Yield Strength* dan *Tensile Strength* AA6016 T4 aluminium alloy sheet.



Gambar 2.6 Kurva pengujian *Yield Strength* dan *Tensile Strength* AA6016 T4 aluminium alloy sheet[21]

2.2 Database Material

Database material adalah kumpulan data yang berisi informasi tentang berbagai jenis material yang digunakan dalam konteks pemodelan machine learning. Database ini dapat mencakup data fisik, kimia, mekanik, termal, dan properti lainnya dari material-material tersebut. Tujuan utama dari database material adalah untuk menyediakan informasi yang diperlukan untuk menganalisis, memodelkan, dan memprediksi perilaku material menggunakan teknik *machine learning*. Pada penelitian ini sumber referensi database material aluminium diambil pada website *makeitfrom.com*, berikut adalah tampilan halaman webnya pada Gambar 2.7[22].



Gambar 2.7 Referensi Database material untuk material aluminium dari website *makeitfrom.com*[22]

Peran database material dalam pemodelan *machine learning* sangat penting. Berikut adalah beberapa peran utama yang dimainkan oleh database material:

1. Sumber Data

Database material menyediakan sumber data yang kaya dan diversifikasi untuk melatih model *machine learning*. Data ini dapat mencakup properti fisik seperti kekerasan, kekuatan, konduktivitas termal, dan properti kimia seperti struktur kristal, komposisi kimia, dan sifat-sifat reaktif material. Data tersebut digunakan untuk melatih model dalam membuat prediksi dan mengambil keputusan terkait material.

2. Pemilihan Material

Database material membantu dalam memilih material yang tepat untuk aplikasi tertentu. Dengan menggunakan informasi yang tersedia dalam database, model *machine learning* dapat melakukan analisis dan pemodelan untuk memprediksi performa material dalam kondisi tertentu. Hal ini memungkinkan pengguna untuk memilih material yang paling cocok dengan kebutuhan mereka, berdasarkan prediksi yang dibuat oleh model *machine learning*.

3. Prediksi Properti Material

Database material digunakan untuk melatih model *machine learning* untuk memprediksi properti material yang tidak terukur atau mahal untuk diuji. Misalnya, dengan menggunakan data properti material yang ada, model dapat mempelajari pola dan hubungan antara struktur dan sifat material. Setelah model dilatih, ia dapat digunakan untuk memprediksi properti material baru berdasarkan struktur atau komposisi kimia yang diberikan.

4. Optimalisasi Material

Database material juga digunakan dalam pemodelan *machine learning* untuk mengoptimalkan material yang ada. Model dapat digunakan untuk mencari kombinasi komposisi, struktur, atau perlakuan panas yang menghasilkan material dengan sifat-sifat yang diinginkan. Dalam beberapa kasus, model dapat memberikan wawasan baru tentang struktur material yang tidak dapat ditemukan secara konvensional.

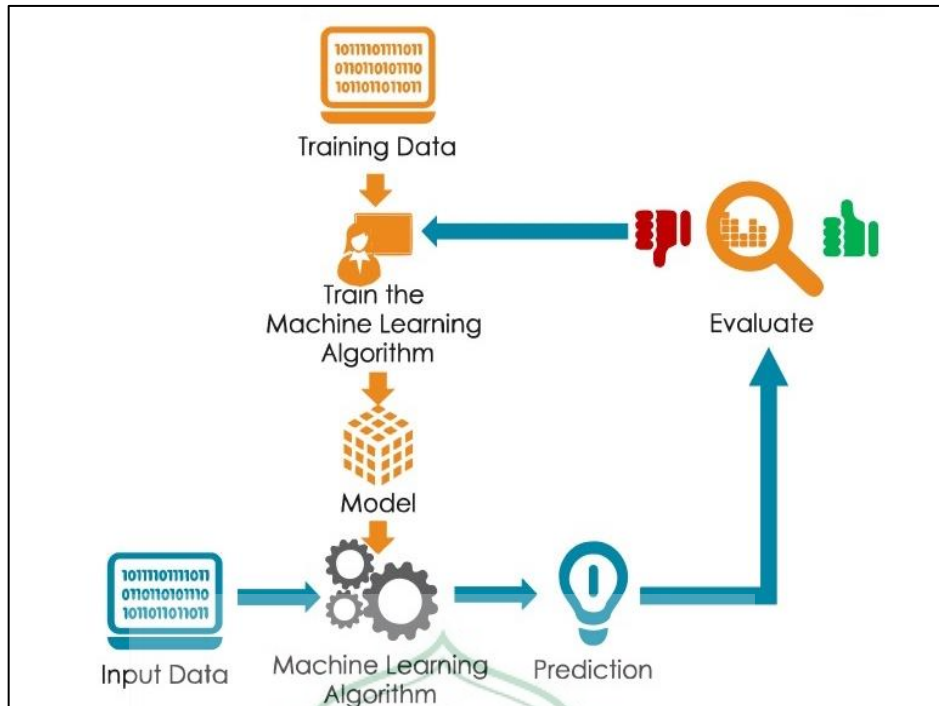
5. Analisis Data Material

Database material memberikan kerangka kerja yang diperlukan untuk analisis data material yang lebih luas. Model *machine learning* dapat digunakan untuk menganalisis keterkaitan antara properti material yang berbeda, mengidentifikasi korelasi yang tidak terlihat sebelumnya, atau mengungkap pola tersembunyi dalam dataset material yang besar. Analisis semacam itu dapat memberikan wawasan yang berharga untuk mengembangkan pemahaman lebih lanjut tentang material dan mengarah pada penemuan baru.

Dengan demikian, database material dan pemodelan *machine learning* saling mendukung satu sama lain dalam mengembangkan pemahaman material yang lebih baik, mempercepat pengembangan material baru, dan meningkatkan efisiensi desain dan pengoptimalan material dalam berbagai aplikasi.

2.3 *Machine Learning*

Machine learning merupakan salah satu pendekatan yang digunakan pada data mining. Pendekatan *machine learning* dapat menangani masalah dengan menemukan model algoritma yang tepat dan lebih baik dalam menghasilkan nilai prediksi dari sebuah variabel input. Hal ini bisa dilakukan karena metode *machine learning* menginterpretasikan bagaimana komputer dapat belajar, bekerja atau memperbaiki performansi berdasarkan data. Metode ini disebut sebagai metode yang dapat membuat keputusan yang tepat dan cerdas dari kompleksitas pola data. *Machine learning* merupakan pendekatan yang cepat berkembang dan beradaptasi [23]. Berikut ilustrasi dari cara kerja *machine learning* dalam analisis suatu data yang dapat dilihat pada Gambar 2.8.



Gambar 2.8 Ilustrasi skema cara kerja *machine learning* [24]

Pendekatan *machine learning* memiliki 4 kategori yang umumnya diaplikasikan pada konsep data mining[25]:

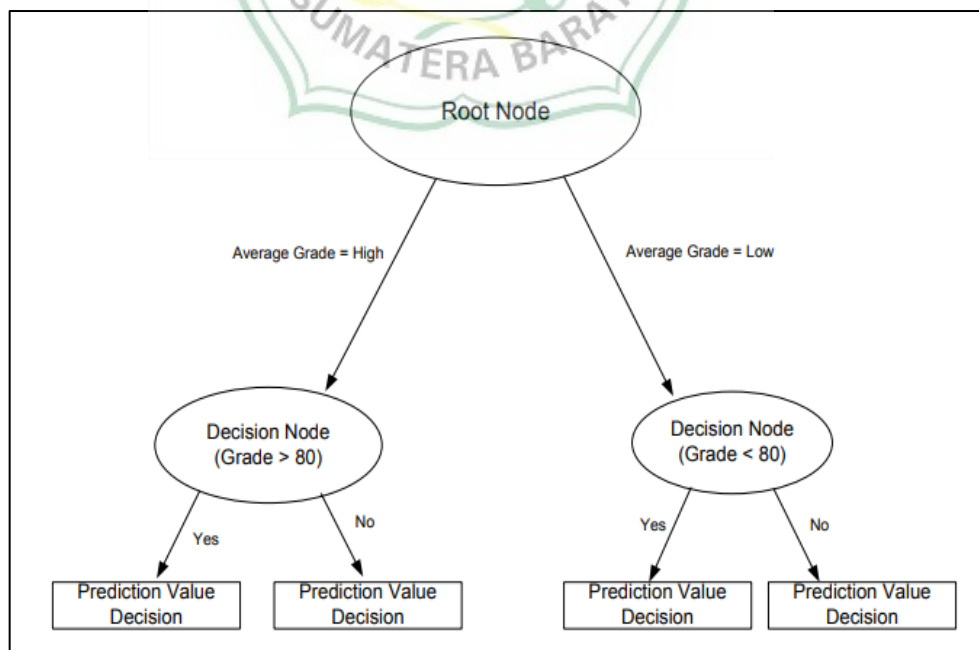
1. *Supervised learning* sering disebut sebagai metode klasifikasi. Metode ini berawal dari data label pada training dataset. Hal pertama pada proses klasifikasi yaitu tahapan mempelajari mapping atau fungsi dimana dapat memprediksi kelas yang terkait dengan label dari sebuah input . Metode ini dapat menggunakan dataset dari berbagai sumber baik itu data yang mudah dipahami atau data dengan tingkat kerumitan yang tinggi.
2. *Unsupervised learning* merupakan metode pengelompokan (*clustering*). Proses clustering sendiri adalah bertujuan untuk mengelompokkan obyek untuk menemukan kelas-kelas data yang tidak diketahui pada dataset.
3. *Semi-supervised learning* merupakan teknik machine learning dimana untuk mempelajari model algoritma menggunakan dua jenis data yaitu *labeled data* dan *unlabeled data*. Dalam arti, *labeled data* digunakan untuk mengetahui dan mempelajari model yang digunakan sementara *unlabeled data* digunakan sebagai batasan antara masing-masing kelas pada model. *Unlabeled data* yang dimaksud dapat dikelompokkan

menjadi kategori positif atau negatif dimana masing-masing berperan menjadi batasan dalam menentukan keputusan.

4. *Active learning*, salah satu pendekatan *machine learning* dimana user berperan aktif dalam proses pendekatan. Pengguna dapat melakukan pelabelan pada contoh data dimana kemungkinan data merupakan unlabeled data atau dataset yang dihasilkan oleh perpaduan dari hasil pembelajaran program. Tujuan metode ini adalah untuk mengoptimalkan kualitas model dengan cara memberikan peran atau pemahaman user untuk membuat batasan jumlah data yang akan diuji sesuai dengan kebutuhan user.

2.3.1 *Decision Tree*

Decision tree merupakan salah satu algoritma klasifikasi yang menarik untuk melakukan pengukuran menggunakan struktur pohon yang terdiri dari kumpulan *decision node* yang dihubungkan oleh cabang-cabang dari *decision root* sampai ke *leaf node*. Algoritma ini digunakan untuk menguji setiap atribut-atribut yang memungkinkan untuk menghasilkan keputusan-keputusan baru sampai pada akhirnya menemukan keputusan yang tepat (*leaf node*) Gambar 2.9.



Gambar 2.9 Model *Decision Tree*[26]

Data dalam *Decission Tree* biasanya direpresentasikan dalam bentuk tabel yang berisi atribut dan *record*. Atribut menyatakan parameter yang akan digunakan sebagai dasar dalam pembentukan Tree. Misalnya, untuk menentukan tingkat risiko manusia terserang Stroke, perlu dipertimbangkan kriteria seperti riwayat sakit jantung, kadar glukosa, pola hidup, jenis pekerjaan, status merokok, jenis kelamin. Salah satu atribut yang digunakan untuk merincikan Data dalam solusi per-Data diistilahkan dengan atribut target. Sedangkan atribut sendiri memiliki nilai yang diistilahkan dengan instance[27].

Pohon keputusan melalui proses berupa mengalih bentuk data tabel menjadi model pohon, mengalih bentuk model pohon menjadi aturan, kemudian menyederhanakan aturan. Langkah pertama dalam membangun *Decission Tree* adalah menghitung nilai entropy total dari jumlah sampel data, kemudian mengelompokkan variabel untuk nilai gain pada setiap atribut. Ketika perhitungan selesai, atribut dengan nilai gain tertinggi menjadi akar, atribut lainnya menjadi cabang, cabang tersebut kemudian dihitung ulang untuk melihat atribut lain yang mempunyai nilai *Gain* tertinggi. Langkah perhitungan tersebut dilakukan berulang-ulang secara terus menerus sehingga semua atribut tereksekusi[27].

Manfaat utama menggunakan *Decission Tree* adalah dapat memecahkan proses pengambilan keputusan yang kompleks menjadi lebih sederhana sehingga. Hal ini memungkinkan proses pengambil keputusan untuk menginterpretasikan solusi, bukan masalah. Pohon Keputusan juga membantu untuk mengeksplorasi data dan menemukan hubungan tersembunyi antara beberapa variabel input dengan variabel target. *Decission Tree* menggabungkan eksplorasi data dan pemodelan dan merupakan langkah pertama dalam proses pemodelan bahkan ketika digunakan sebagai model akhir untuk teknik lain[28].

Decission Tree juga dikenal sebagai diagram alur, berbentuk seperti struktur pohon, dengan setiap *internal node* menyatakan pengujian atribut, setiap cabang mewakili output dari hasil pegujian, dan inode daun (*leaf node*) menyatakan distribusi kelas. *Node* teratas disebut sebagai simpul akar (*root node*). Pohon keputusan digunakan untuk mengklasifikasikan sampel data yang kelasnya belum diketahui ke dalam kelas yang sudah ada. Dalam jalur pengujian data, semua data harus terlebih dahulu melalui *root node* dan terakhir melalui *leaf node*. Ini yang

akan menyimpulkan prediksi kelas bagi data tersebut. Atribut data harus berupa data kategorial. Jika kontinu, atribut harus didiskritisasi terlebih[25].

Metode *Decision Tree* memiliki beberapa keunggulan dibandingkan metode lain untuk Database besar, yaitu[25]:

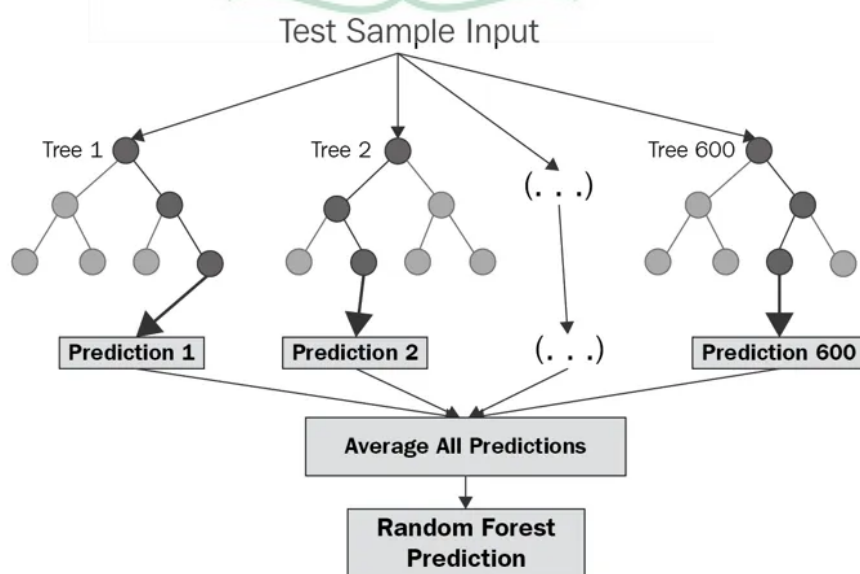
1. Memiliki kecepatan yang relatif lebih cepat.
2. Dapat diubah menjadi rule klasifikasi dengan mudah dan sederhana.
3. Dapat menggunakan *query SQL* untuk mengakses Database.
4. Akurasi tinggi dibandingkan dengan metode lain.

2.3.2 *Random forest*

Random Forest adalah algoritma *supervised learning* yang dikeluarkan oleh Breiman pada tahun 2001. *Random Forest* biasa digunakan untuk menyelesaikan masalah yang berhubungan dengan klasifikasi, regresi, dan sebagainya[29]. Ada dua hal yang membuat algoritma ini disebut random, yaitu:

1. Setiap pohon tumbuh pada sampel *bootstrap* yang berbeda diambil dari data latih secara acak.
2. Dalam setiap node split selama pembentukan *decision tree*, sebagian sampel dari m variabel dipilih dari kumpulan data yang asli dan kemudian yang terbaik akan digunakan dalam node tersebut.

Berikut merupakan ilustrasi skema *random forest* yang dapat dilihat pada gambar 2.10.



Gambar 2.10 Model *Random Forest*[30]

Algoritma ini berupa kombinasi dari beberapa *tree predictors* atau bisa disebut *decision trees* dimana setiap *tree* bergantung pada nilai *random vector* yang dijadikan sampel secara bebas dan merata pada semua *tree* dalam *forest* tersebut. Hasil prediksi dari *Random Forest* didapatkan melalui hasil terbanyak dari setiap individual *decision tree* (*voting* untuk klasifikasi dan rata-rata untuk regresi). Untuk RF yang terdiri dari N *trees* dapat dihitung dengan persamaan 2.5 sebagai berikut [31]:

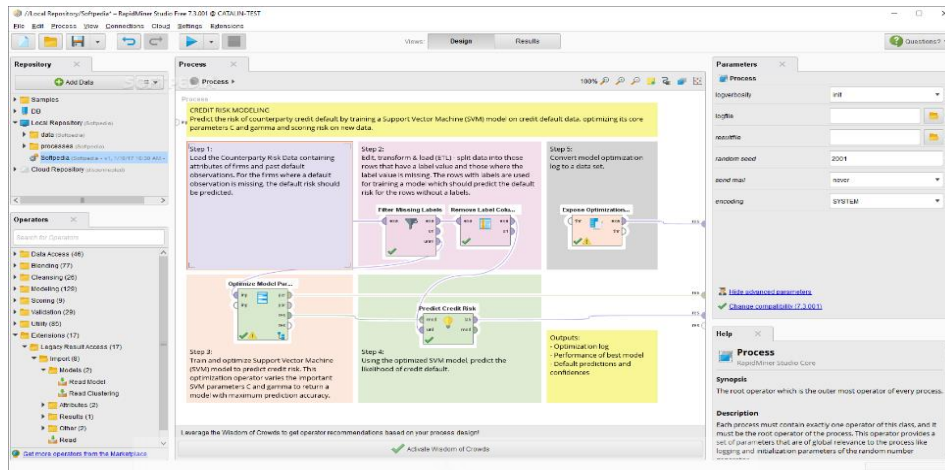
$$l(y) = \underset{c}{\operatorname{argmax}} \left(\sum_{n=1}^N l_{h_n}(y) = c \right) \dots\dots\dots (2.5)$$

Dimana l adalah fungsi indikator dan h_n adalah tree ke- n dari RF. *Random Forest* memiliki mekanisme internal yang menyediakan estimasi dari *generalization error*-nya sendiri yang disebut *out-of-bag (OOB) error estimate*. Dalam pembentukan tree hanya 2/3 dari data asli yang digunakan dalam pengambilan sampel bootstrap. Sedangkan 1/3 sisanya diklasifikasikan oleh *tree* yang terbentuk dan digunakan untuk menguji performanya. *OOB error estimation* adalah rata-rata dari kesalahan prediksi untuk setiap kasus training y menggunakan *tree* yang tidak mengikutsertakan y dalam sampel *bootstrap*-nya. Kemudian, saat RF dibuat, semua training cases menyusuri setiap pohon dan matriks kedekatan setiap kasus dihitung berdasarkan pasangan kasus yang sampai di terminal *node* yang sama[31].

2.4 *Rapid Miner*

Rapid Miner merupakan perangkat lunak yang bersifat terbuka (open source). *Rapid Miner* adalah sebuah solusi untuk melakukan analisis terhadap data mining, text mining dan analisis prediksi. *Rapid Miner* menggunakan berbagai teknik deskriptif dan prediksi dalam memberikan wawasan kepada pengguna sehingga dapat membuat keputusan yang paling baik. *Rapid Miner* memiliki kurang lebih 500 operator data mining, termasuk operator untuk input, output, data preprocessing dan visualisasi. *Rapid Miner* merupakan *software* yang berdiri sendiri untuk analisis data dan sebagai mesin data mining yang dapat diintegrasikan pada produknya sendiri. *Rapid Miner* ditulis dengan menggunakan bahasa java

sehingga dapat bekerja di semua sistem operasi[32]. Berikut adalah tampilan Tampilan *software Rapid Miner* yang dapat dilihat pada Gambar 2.11.



Gambar 2.11 Tampilan *software Rapid Miner*[32]

Rapid Miner sebelumnya bernama *YALE (Yet Another Learning Environment)*, dimana versi awalnya mulai dikembangkan pada tahun 2001 oleh RalfKlinkenberg, Ingo Mierswa, dan Simon Fischer di *Artificial Intelligence Unit* dari University of Dortmund. *Rapid Miner* didistribusikan di bawah lisensi *AGPL (GNU Affero General Public License)* versi 3. Hingga saat ini telah ribuan aplikasi yang dikembangkan menggunakan *Rapid Miner* di lebih dari 40 negara. *Rapid Miner* sebagai *software open source* untuk data mining tidak perlu diragukan lagi karena software ini sudah terkemuka di dunia. *Rapid Miner* menempati peringkat pertama sebagai *Software* data mining pada *polling* oleh *KD nuggets*, sebuah portal data-mining pada 2010-2011.

Rapid Miner menyediakan *GUI (Graphic User Interface)* untuk merancang sebuah pipeline analitis. *GUI* ini akan menghasilkan file *XML (Extensible Markup Language)* yang mendefinisikan proses analitis keinginan pengguna untuk diterpkan ke data. File ini kemudian dibaca oleh *Rapid Miner* untuk menjalankan analisis secara otomatis.

Rapid Miner memiliki beberapa sifat sebagai berikut [32]:

1. Ditulis dengan bahasa pemrograman *Java* sehingga dapat dijalankan di berbagai sistem operasi.
2. Proses penemuan pengetahuan dimodelkan sebagai operator *trees*.

3. Representasi XML internal untuk memastikan format standar pertukaran data.
4. Bahasa *scripting* memungkinkan untuk eksperimen skala besar dan otomatisasi eksperimen.
5. Konsep multi-layer untuk menjamin tampilan data yang efisien dan menjamin penanganan data.
6. Memiliki GUI, *command line mode*, dan Java API yang dapat dipanggil dari program lain.

Beberapa Fitur dari RapidMiner, antara lain:

1. Banyaknya algoritma data mining, seperti *decision tree* dan *self-organization map* [29].
2. Bentuk grafis yang canggih, seperti tumpang tindih diagram histogram, *tree chart* dan *3D Scatter plots*.
3. Banyaknya variasi plugin, seperti text plugin untuk melakukan analisis teks.
4. Menyediakan prosedur data mining dan machine learning termasuk: ETL (*extraction, transformation, loading*), data *preprocessing*, visualisasi, *modelling* dan evaluasi.
5. Proses data mining tersusun atas operator-operator yang *nestable*, dideskripsikan dengan XML, dan dibuat dengan GUI.
6. Mengintegrasikan proyek data mining Weka dan statistika R.

2.5 Dataset

Dalam penelitian ini, dataset yang diperlukan mencakup data sifat mekanik aluminium dan unsur kimia paduannya. Tujuan dari penelitian ini adalah untuk mengembangkan dan menguji model *Machine Learning* yang dapat memprediksi sifat mekanik aluminium berdasarkan unsur kimia yang terkandung dalam paduannya. Dataset ini akan menjadi sumber informasi yang penting dalam melatih dan menguji model tersebut.

Dataset akan terdiri dari dua komponen utama. Pertama, data sifat mekanik aluminium akan mencakup variabel-variabel seperti kekuatan tarik, kekuatan leleh, kekerasan, dan elastisitas. Data ini akan diperoleh melalui pengujian laboratorium

menggunakan metode yang telah ditentukan secara standar. Kedua, dataset juga akan mencakup informasi tentang unsur kimia yang digunakan sebagai paduan dalam aluminium. Komposisi kimia paduan ini akan mencakup jenis dan jumlah unsur tambahan yang ditambahkan ke aluminium murni.

Selain melatih model, dataset ini juga akan digunakan untuk menguji keefektifan dan keakuratan model yang dikembangkan. Sebagian dataset akan digunakan sebagai data uji yang tidak digunakan dalam proses pelatihan, sehingga dapat digunakan untuk menguji kemampuan model dalam memprediksi sifat mekanik aluminium dengan akurasi yang tinggi.

Dalam kesimpulannya, dataset yang mencakup data sifat mekanik aluminium dan unsur kimia paduannya akan menjadi bagian penting dalam penelitian ini. Dataset ini akan digunakan untuk melatih dan menguji model Machine Learning yang bertujuan untuk mempelajari pola dan hubungan antara sifat mekanik aluminium dengan unsur kimia paduannya. Dengan menggunakan dataset ini, diharapkan penelitian ini dapat memberikan kontribusi dalam pemahaman dan prediksi sifat mekanik aluminium secara lebih akurat dan efisien. Pada Gambar 2.12 dibawah ini adalah tampilan dataset yang terdapat dalam aplikasi *rapidminer*.

Row No.	Spesimen	Mg	Zn	Ti	Cu	Mn	Cr	Fe	Si	Al
1	5454 O	1.400	0.200	0.200	0.100	0.500	0.050	0.400	0.250	96.840
2	AA 5083	1.400	0.250	0.150	0.100	0.400	0.050	0.400	0.400	96.850
3	5454 H32	1.400	0.250	0.200	0.100	0.500	0.050	0.400	0.250	96.850
4	5454 H24	1.400	0.200	0.200	0.100	0.500	0.050	0.400	0.250	96.840
5	5050 H32	1.100	0.250	0	0.200	0.100	0.100	0.700	0.400	97.150
6	5050 H34	1.100	0.250	0	0.200	0.100	0.100	0.700	0.400	97.150
7	5050 H18	1.100	0.250	0	0.200	0.100	0.100	0.700	0.400	97.150
8	1050A O	0.050	0.070	0.050	0.050	0.050	0	0.400	0.250	99.080
9	1050A H111	0.050	0.070	0.040	0.050	0.050	0	0.400	0.250	99.080
10	5050 O	1.100	0.220	0	0.200	0.100	0.100	0.700	0.400	97.180
11	1050A H24	0.050	0.070	0.050	0.050	0.050	0	0.400	0.250	99.080
12	1050A H22	0.050	0.070	0.050	0.050	0.050	0	0.400	0.250	99.080
13	1080A O	0.020	0.050	0	0.030	0.020	0	0.150	0.150	99.580
14	1080A H12	0.020	0.060	0	0.030	0.020	0	0.150	0.150	99.570
15	1080A H16	0.020	0.060	0	0.030	0.020	0	0.150	0.150	99.570
16	1200 O	0	0.100	0.050	0.050	0.050	0	1	1	97.750
17	1200 h24	0	0.100	0.060	0.050	0.050	0	1	1	97.740

Gambar 2.12 Dataset[32]

Pada penelitian ini, pengolahan data memainkan peran penting dalam mempersiapkan dataset untuk pelatihan dan pengujian model Machine Learning. Beberapa teknik pengolahan data yang mungkin diperlukan adalah normalisasi data, pemilihan fitur, dan pemisahan dataset menjadi data latih dan data uji.

Pertama, normalisasi data digunakan untuk mengubah skala data menjadi rentang yang seragam. Hal ini penting karena data yang memiliki skala yang berbeda-beda dapat mempengaruhi kinerja model. Dengan menerapkan teknik normalisasi, seperti *Z-score* atau *Min-Max scaling*, data dapat diubah menjadi distribusi yang lebih seragam, sehingga memudahkan model untuk mempelajari pola dan hubungan di antara variabel.

Kedua, pemilihan fitur adalah proses memilih subset fitur yang paling relevan dan berpengaruh dalam memprediksi sifat mekanik aluminium. Hal ini bertujuan untuk mengurangi dimensi dataset, menghilangkan fitur yang tidak relevan atau redundant, serta meningkatkan efisiensi dan keakuratan model. Teknik pemilihan fitur, seperti analisis korelasi, pengujian statistik, atau algoritma pemilihan fitur seperti *Recursive Feature Elimination* (RFE), dapat digunakan untuk mengidentifikasi fitur-fitur yang paling informatif.

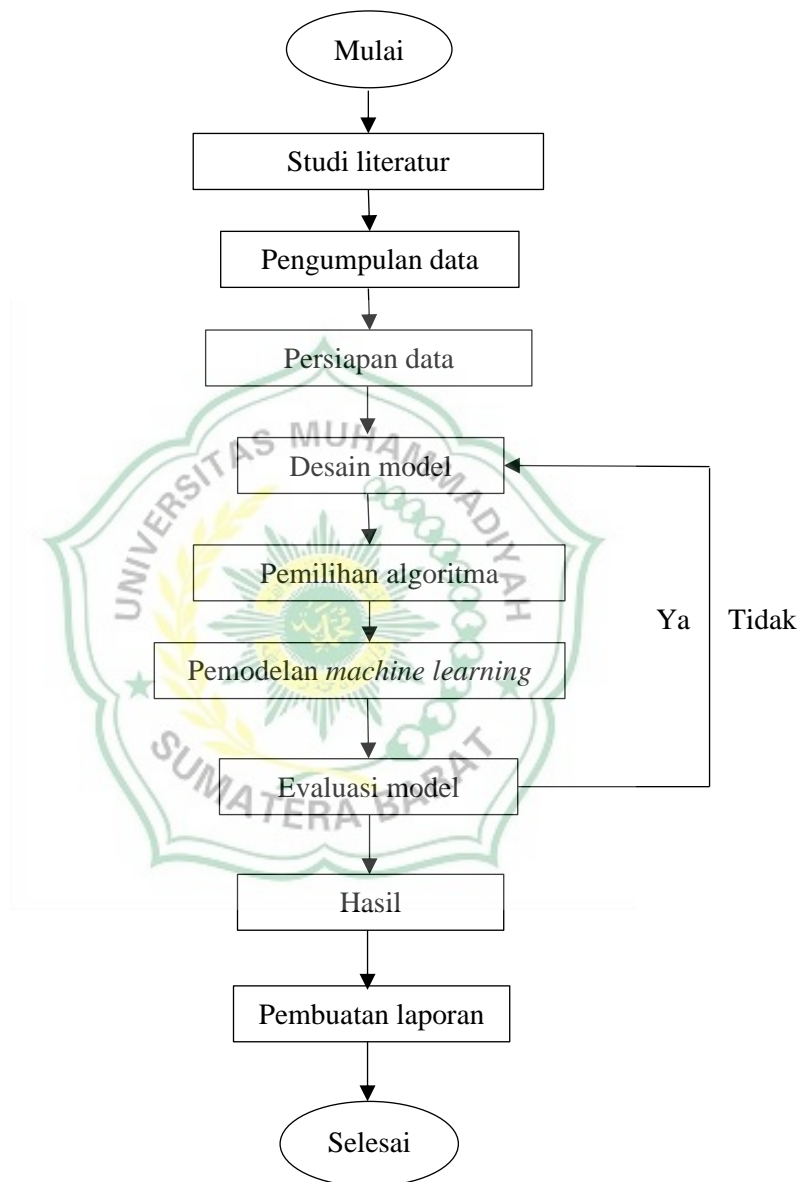
Selain itu, pemisahan dataset menjadi data latih dan data uji adalah langkah penting dalam evaluasi model. Sebagian dataset akan digunakan sebagai data latih untuk melatih model, sementara sebagian lainnya akan digunakan sebagai data uji untuk menguji kinerja model yang sudah dilatih. Pemisahan ini memungkinkan kita untuk mengukur sejauh mana model mampu menggeneralisasi pada data yang belum pernah dilihat sebelumnya, dan mengevaluasi keefektifan model secara obyektif.

Dalam kesimpulannya, beberapa teknik pengolahan data, seperti normalisasi data, pemilihan fitur, dan pemisahan dataset menjadi data latih dan data uji, diperlukan dalam penelitian ini. Dengan menerapkan teknik-teknik ini, dataset dapat disiapkan dengan baik untuk melatih dan menguji model Machine Learning. Pengolahan data yang tepat akan memastikan bahwa model dapat bekerja secara efisien, menghasilkan prediksi yang akurat, dan memberikan kontribusi yang berarti dalam pemahaman sifat mekanik aluminium berdasarkan unsur kimia paduannya.

BAB III METODE PENELITIAN

3.1 Diagram Alir Penelitian

Berikut adalah diagram alir penelitian yang dapat dilihat pada Gambar 3.1.



Gambar 3.1 Diagram alir penelitian

3.2 Tempat dan waktu Penelitian

Penelitian ini dilakukan di labor Fakultas Teknik Mesin UM. Sumatera Barat, Data penelitian ini diambil pada periode April 2023 dari *website makeitfrom.com*.

adalah sebuah database kurasi properti material teknik yang menekankan kemudahan perbandingan. Situs ini bukanlah sekadar kumpulan data mentah, melainkan setiap bahan yang terdaftar di dalamnya adalah bahan generik yang diakui secara internasional. Data yang ada berasal dari standar yang telah diterbitkan, literatur akademik, dan dokumentasi dari pemasok bahan yang dibuka untuk akademik [33].

3.3 Alat dan Bahan

Adapun alat dan bahan yang digunakan dalam penelitian ini yaitu :

1. *Dataset*

Data yang digunakan dalam penelitian ini berasal dari *website makeitfrom.com*. *makeitfrom.com* adalah sebuah database akurasi properti material teknik yang menekankan kemudahan perbandingan. Dataset ini berisi informasi tentang komposisi kimia paduan dan sifat mekanik baja tahan karat yang relevan untuk analisis yang dilakukan.

2. Laptop Intel B815-PC

Laptop yang digunakan dalam penelitian ini adalah sebuah Laptop dengan spesifikasi Intel B815-PC. Laptop ini digunakan sebagai alat untuk menjalankan perangkat lunak *RapidMiner* dan melakukan proses analisis data.

3. Perangkat Lunak *RapidMiner*

Penelitian ini menggunakan perangkat lunak *RapidMiner* sebagai alat utama untuk melakukan analisis data. *RapidMiner* merupakan platform analisis data yang memungkinkan eksplorasi dan analisis data secara visual, serta menyediakan berbagai metode statistik dan algoritma yang dapat digunakan dalam penelitian.

4. Sumber Referensi

Selama proses penelitian, berbagai sumber referensi digunakan untuk memperoleh informasi yang diperlukan tentang aluminium, komposisi kimia paduan, dan sifat mekanik. Sumber-sumber ini termasuk jurnal ilmiah, buku teks, laporan teknis, dan publikasi terkait lainnya.

3.4 Metode Penelitian

Penelitian ini menggunakan metode Prediksi Sifat Mekanik Aluminium Berdasarkan Unsur Kimia Paduan Menggunakan Model *Machine Learning*. Tujuannya adalah untuk mengidentifikasi pola, hubungan, dan anomali dalam data serta mendapatkan wawasan yang berharga sebelum melakukan analisis lebih lanjut [3]. Metode ini terdiri dari beberapa tahap sebagai berikut :

1. Studi Literatur

Metode awal dalam penelitian ini adalah studi literatur yang bertujuan untuk memperoleh pemahaman yang komprehensif mengenai sifat mekanik baja tahan karat, komposisi kimia paduan yang umum digunakan, serta perlakuan panas yang dapat mempengaruhi sifat mekanik material. Pada tahap studi literatur, dilakukan pencarian dan pengumpulan informasi dari sumber-sumber tepercaya seperti jurnal ilmiah, buku referensi, artikel, dan database terkait. Data yang relevan diambil untuk memperoleh pemahaman yang mendalam tentang topik penelitian, termasuk teori dan konsep dasar, metode yang digunakan sebelumnya, dan temuan-temuan terkait.

2. Pengumpulan Data

Data yang digunakan dalam penelitian ini berasal dari dataset *Materials Algorithms Project* yang dikelola oleh dari *website makeitfrom.com*. Dataset ini berisi informasi tentang komposisi kimia paduan, suhu perlakuan panas dan sifat mekanik baja tahan karat.

3. Persiapan Data

Data yang telah dikumpulkan kemudian dipersiapkan untuk dianalisis dengan *RapidMiner*. Proses persiapan data melibatkan langkah-langkah seperti pemilihan variabel yang relevan, penghapusan *missing values* (nilai yang hilang), penanganan outliers (nilai ekstrem), dan normalisasi data jika diperlukan. Tujuan dari tahap ini adalah untuk memastikan kualitas data yang optimal sebelum dilakukan analisis lebih lanjut.

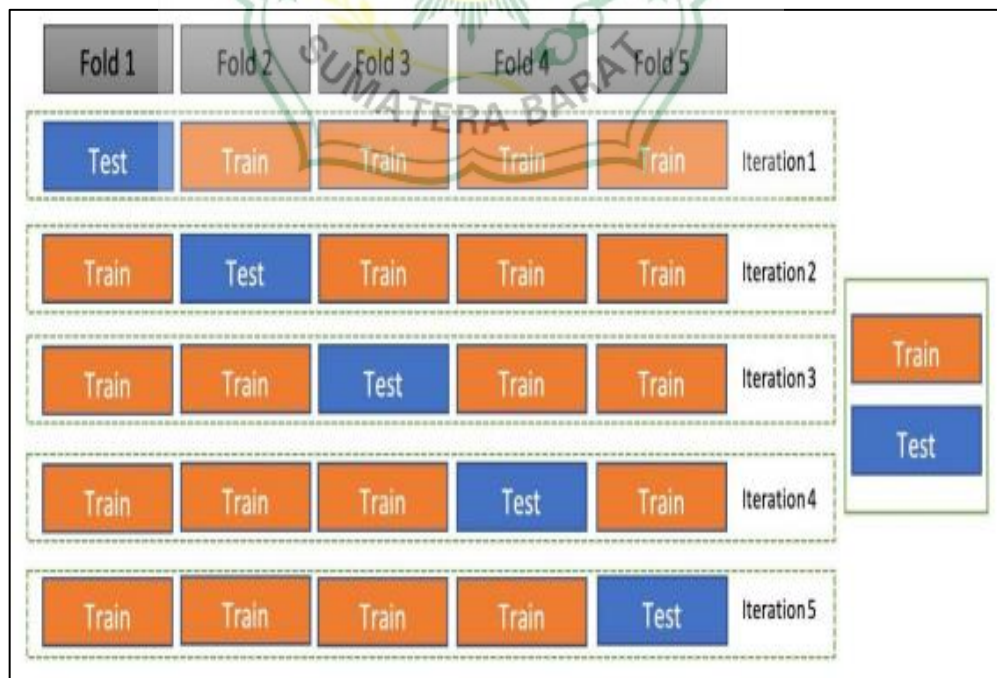
4. Desain Model: Menggunakan Penelitian ini menggunakan perangkat lunak *RapidMiner* sebagai alat utama untuk melakukan analisis data. *RapidMiner* merupakan platform analisis data yang memungkinkan eksplorasi dan

analisis data secara visual, serta menyediakan berbagai metode statistik dan algoritma yang dapat digunakan dalam penelitian.

5. Pemilihan Algoritma

Algoritma yang digunakan dalam penelitian ini adalah *random forest* dan *decision tree*.

6. Validasi Model: Model yang telah dibuat kemudian diuji dengan menggunakan metode *cross validation k-fold* dengan jumlah fold sebanyak 5 untuk memastikan model tersebut dapat digeneralisasikan pada data baru dengan baik. Banyak teknik pembelajaran mesin membagi data asli ke dalam set pelatihan dan set pengujian, menggunakan set pelatihan untuk pelatihan model, dan set pengujian untuk validasi model[35]. Penelitian ini menggunakan $K\text{-Fold} = 5$, Salah satu alasan utama menggunakan *cross validation K-fold* dengan $K = 5$ adalah karena memberikan keseimbangan yang baik antara bias dan varians. Pada $K\text{-fold cross validation}$ memberikan jumlah data latihan dan validasi yang baik yang cukup untuk membuat model generalisasi dengan baik dan mendapatkan akurasi yang baik dapat dilihat pada Gambar 3.2.



Gambar 3.2 Ilustrasi set pelatihan (*orange*) dan pengujian (*biru*) untuk $k = 5$ [36]

7. Evaluasi Model

Pemodelan dalam penelitian ini memiliki 9 variabel data input dan 2 data output sebagai target, setiap pemodelan yang dihasilkan dari setiap algoritma di evaluasi dengan menghitung nilai *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Squared Correlation* (SC), berdasarkan nilai aktual dan nilai prediksi dari data uji yang dapat dilihat pada perasamaan berikut[36]:

Mean Absolute Error (MAE) adalah metrik yang digunakan untuk mengukur sejauh mana perbedaan antara nilai-nilai yang diprediksi oleh suatu model dengan nilai-nilai yang sebenarnya. Dalam konteks statistik dan analisis prediktif, MAE mengukur rata-rata dari selisih absolut antara prediksi dan nilai sebenarnya dari suatu variabel.

$$MAE = \frac{1}{N} \sum |y_i - z_i| \dots\dots\dots (3.6)$$

Dimana :

i adalah indeks dari data pada sample, N adalah jumlah total *sample*, y_i adalah nilai aktual dari data ke- i , sedangkan z_i adalah nilai prediksi dari model untuk data ke- i [5]

Root Mean Squared Error (RMSE) adalah salah satu metrik yang digunakan untuk mengukur sejauh mana perbedaan antara nilai-nilai prediksi dan nilai-nilai aktual dalam suatu dataset. Metrik ini sering digunakan dalam bidang statistik dan ilmu data untuk mengevaluasi kinerja model prediksi atau estimasi.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f(X_i) - Y_i)^2} \dots\dots\dots (3.7)$$

Dimana:

n adalah jumlah data yang digunakan untuk menguji model, $f(X_i)$ adalah nilai yang diprediksi oleh model untuk data ke- i , Y_i adalah nilai sebenarnya untuk data ke- i .

Squared Correlation (SC) adalah ukuran statistik yang mengukur tingkat hubungan antara dua variabel. Dalam konteks ini, R merujuk pada Koefisien Korelasi Pearson, yang paling umum digunakan untuk mengukur hubungan linier antara dua variabel kontinu.

$$SC = \frac{\sum_{i=1}^n (f(X_i) - f(X))(Y_i - Y)}{\sqrt{\frac{1}{n} \sum_{i=1}^n (f(X_i) - f(X))^2} \sqrt{\sum_{i=1}^n (Y_i - Y)^2}} \dots\dots\dots (3.8)$$

Dimana :

$f(X_i)$ adalah nilai prediksi dari variabel dependen (Y) berdasarkan variabel independen (X) pada observasi ke-i, $f(X)$ adalah rata – rata dari semua prediksi $f(X_i)$ pada seluruh observasi, Y_i adalah nilai observasi actual dari variabel dependen pada observasi ke-i, Y adalah rata – rata dari semua nilai observasi Y_i pada seluruh observasi, dan n adalah jumlah total observasi.

8. Analisis Sifat Mekanik

Setelah dilakukan Prediksi Sifat Mekanik Aluminium, analisis sifat mekanik dilakukan menggunakan teknik analisis yang tersedia dalam RapidMiner. Metode visualisasi antara unsur kimia paduan, suhu perlakuan panas dan sifat mekanik seperti *yield strength* (YS) dan *tensile strength* (TS) dapat diterapkan pada data aluminium paduan. Hasil analisis ini akan memberikan wawasan tentang kekuatan, ketahanan, dan karakteristik mekanik material.

9. Interpretasi dan Kesimpulan

Setelah melalui tahap analisis, hasil yang diperoleh dari RapidMiner akan diinterpretasikan dan dievaluasi secara menyeluruh.

BAB IV DATA dan PEMBAHASAN

4.1 Data

Data penelitian ini diambil pada periode April 2023 dari *website makeitfrom.com*. *makeitfrom.com* adalah sebuah database kurasi properti material teknik yang menekankan kemudahan perbandingan. Situs ini bukanlah sekedar kumpulan data mentah, melainkan setiap bahan yang terdaftar di dalamnya adalah bahan generik yang diakui secara internasional. Data yang ada berasal dari standar yang telah diterbitkan, literatur akademik, dan dokumentasi dari pemasok bahan.

Data yang tersedia seperti sifat mekanik material, komposisi kimia, korosi, perlakuan panas, sifat termal dan masih banyak lagi, namun pada penelitian ini data yang diambil adalah data komposisi kimia aluminium, nilai uji tarik aluminium (TS) dan kekuatan luluh aluminium (YS). Data komposisi kimia aluminium yang diambil pada penelitian ini adalah presentase kadar Aluminium (Al), Manganese (Mg), Zinc (Zn), Titanium (Ti), Copper (Cu), Manganese (Mn), Chromium (Cr), Ferrum (Fe), Silicium (Si) yang dapat dilihat pada tabel 1. Pada penelitian ini menggunakan dataset *Aluminium Alloy AA1000* dengan kode AL 1050 dan 1060 yang berjumlah 237 data dengan 9 data input serta 2 data output atau target.

Tabel 4.1 Statistik dataset aluminium

Keterangan	Tipe data	Min	Max	Mean
Mg (%)	Input	0,03	0,05	0,039
Zn (%)	Input	0,05	0,05	0,05
Ti (%)	Input	0,03	0,03	0,03
Cu (%)	Input	0,05	0,05	0,05
Mn (%)	Input	0,03	0,05	0,03842
Cr (%)	Input	0,05	0,05	0,05
Fe (%)	Input	0,35	0,4	0,3725
Si (%)	Input	0,25	0,25	0,25
Al (%)	Input	99,5	99,6	99,555
YS (Mpa)	Output	17	120	73,4
TS (Mpa)	Output	67	140	101,45

Pada penelitian ini digunakan algoritma *decision tree* dan *random forest* menggunakan perbandingan rasio data *training* dan data *testing* sebesar 60:40,

70:30 dan 80:20 80%. Kemudian performa model yang dilatih dievaluasi dengan menghitung *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Correlation Coefficient* (R), dari nilai aktual dan nilai prediksi dari data uji.

Pemodelan dilakukan menggunakan perangkat lunak RapidMiner. Pemodelan ini melibatkan 9 variabel input yang mencakup unsur kimia paduan, serta 2 variabel output, yaitu YS dan TS. Selanjutnya analisis data dilakukan dengan menggunakan *heatmap correlation* yang terdapat pada Gambar 4.1. *Heatmap correlation* adalah sebuah visualisasi grafik yang digunakan untuk menampilkan tingkat korelasi antara dua set data atau variabel. Dalam *heatmap correlation*, setiap sel pada matriks dipresentasikan dengan warna yang menunjukkan tingkat korelasi antara variabel-variabel tersebut. Visualisasi *heatmap correlation* menunjukkan bahwa unsur Mg memiliki korelasi positif tertinggi dengan YS, yakni sebesar 0,620. Kemudian, unsur Ti memiliki korelasi sebesar 0,600, dan unsur Zn sebesar 0,371. Hal ini menandakan bahwa semakin tinggi kadar Mg dalam komposisi kimia paduan aluminium maka, dapat meningkatkan kekuatan *Yield strength* (YS). Terkait dengan kekuatan tarik (TS), unsur Mg memiliki korelasi paling kuat, yaitu 0,879. Pada urutan kedua, unsur Ti memiliki korelasi positif sebesar 0,752, diikuti oleh unsur Cr sebesar 0,688, dan unsur Zn sebesar 0,450. Hal ini menandakan bahwa semakin tinggi kadar Mg dalam komposisi kimia paduan aluminium maka, dapat meningkatkan kekuatan *Tensile strength* (TS).

Attributes	Mg	Zn	Ti	Cu	Mn	Cr	Fe	Si	Al	Yield st...	Tensile ...
Mg	1	0.208	0.827	-0.100	0.157	0.598	-0.326	-0.174	-0.877	0.620	0.879
Zn	0.208	1	0.041	0.782	0.237	0.420	0.237	0.054	-0.434	0.371	0.450
Ti	0.827	0.041	1	-0.330	0.123	0.305	-0.460	-0.181	-0.668	0.600	0.752
Cu	-0.100	0.782	-0.330	1	0.197	0.260	0.366	0.125	-0.169	0.058	0.076
Mn	0.157	0.237	0.123	0.197	1	0.209	0.096	0.143	-0.465	0.221	0.396
Cr	0.598	0.420	0.305	0.260	0.209	1	-0.033	0.087	-0.691	0.261	0.688
Fe	-0.326	0.237	-0.460	0.366	0.096	-0.033	1	0.803	-0.049	-0.174	-0.237
Si	-0.174	0.054	-0.181	0.125	0.143	0.087	0.803	1	-0.182	-0.158	-0.155
Al	-0.877	-0.434	-0.668	-0.169	-0.465	-0.691	-0.049	-0.182	1	-0.593	-0.887
Yield strenght (Mpa)	0.620	0.371	0.600	0.058	0.221	0.261	-0.174	-0.158	-0.593	1	0.639
Tensile strenght (Mpa)	0.879	0.450	0.752	0.076	0.396	0.688	-0.237	-0.155	-0.887	0.639	1

Gambar 4.1 *Heatmap correlation*

4.1.1 Pemodelan *Machine Learning*

Dalam penelitian ini, terdapat dua algoritma *machine learning* yang digunakan untuk pemodelan, yaitu *Random Forest* (RF) dan *Decision Tree* (DT). Untuk memprediksi kekuatan tarik dan kekuatan luluh material aluminium secara akurat, dilakukan variasi pengaturan parameter berupa *maximal depth* untuk algoritma *decision tree* serta *maximal depth* dan *number of trees* untuk algoritma *random forest*. Informasi tentang variasi parameter pada setiap algoritma dapat dilihat pada Tabel 4.2. Tabel tersebut mencakup dua kolom utama, yaitu kolom pertama yang berisi nama algoritma (DT dan RF), kolom kedua yang berisi nama parameter yang akan diberikan, dan kolom ketiga yang berisi pengaturan parameter pada masing-masing algoritma.

Tabel 4.2 Pengaturan parameter untuk mencari algoritma terbaik

No	Algoritma	Nama Parameter	Pengaturan parameter
1.	<i>Decision tree</i>	<i>Criterion</i>	<i>Least square</i>
		<i>Maximal depth</i>	1,2,3,4,5,6,7,8,9,10,11,12
		<i>Ratio</i>	60:40, 70:30, 80:20
2.	<i>Random forest</i>	<i>Number of trees</i>	20,40,60,80,100,120,140,160,180,200
		<i>Criterion</i>	<i>Least square</i>
		<i>Maximal depth</i>	1,2,3,4,5,6,7,8,9,10,11,12
		<i>Ratio</i>	60:40, 70:30, 80:20

Hasil pencarian parameter terbaik dengan berbagai variasi parameter untuk setiap algoritma adalah sebagai berikut :

a. *Decision Tree* (DT)

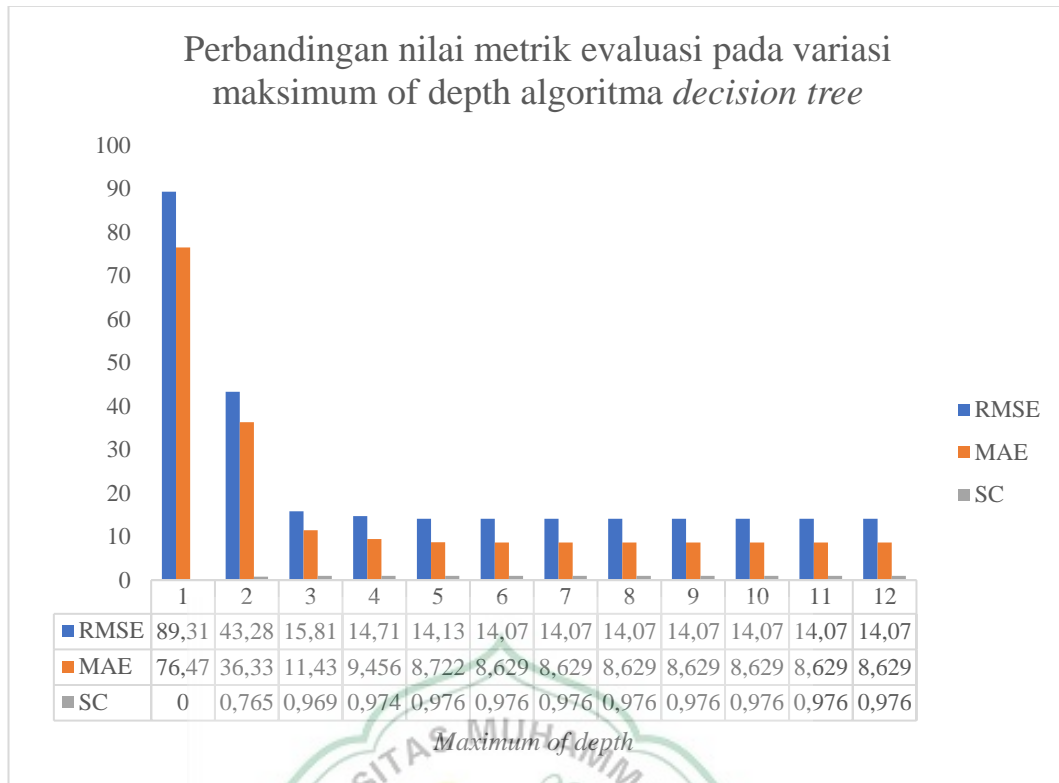
Pada algoritma *decision trees* dilakukan pencarian parameter terbaik dengan memvariasikan jumlah *maksimum of depth*, dimana setiap perubahan nilai *maksimum of depth* di bandingkan nilai metrik evaluasinya. Parameter awal yang digunakan dalam pengujian adalah rasio dataset 60:40 Hasil metrik evaluasi untuk setiap perubahan jumlah maksimal of depth dapat dilihat pada tabel 4.3.

Tabel 4.3 Perbandingan hasil uji variasi nilai *maksimum of depth* algoritma *decision tree* rasio 60:40

No	<i>Maximum of depth</i>	RMSE	MAE	SC
1.	1	89,314	76,472	0
2.	2	43,284	36,329	0,765
3.	3	15,813	11,434	0,969
4.	4	14,707	9,456	0,974
5.	5	14,13	8,722	0,976
6.	6	14,074	8,629	0,976
7.	7	14,074	8,629	0,976
8.	8	14,074	8,629	0,976
9.	9	14,074	8,629	0,976
10.	10	14,074	8,629	0,976
11.	11	14,074	8,629	0,976
12.	12	14,074	8,629	0,976

Berdasarkan hasil tabel 4.3 diatas diketahui bahwasanya terjadi penurunan nilai RMSE dan MAE seiring dengan meningkatnya nilai *maksimum of depth*, berbanding terbalik dengan nilai SC yang mengalami kenaikan.

Untuk mengambil mana parameter terbaik yang akan digunakan diambil nilai RMSE dan MAE terkecil dengan nilai SC tertinggi. Berdasarkan hasil tabel 4.3 diatas diambil nilai *maksimum of depth* sebesar 6 dengan nilai RMSE 14,074, nilai MAE 8,629 dan nilai SC 0,976. Hal ini dikarenakan setelah kenaikan nilai *maksimum of depth* lebih dari 6, tidak ada kenaikan nilai RMSE, MAE dan penurunan nilai SC. Dengan begitu dalam pengujian algoritma *decision tree* selanjutnya diambil nilai *maksimum of depth* sebesar 6. Perbandingan nilai metrik evaluasi pada berbagai jumlah maksimum of depth dapat dilihat pada gambar 4.2.



Gambar 4.2 Grafik perbandingan hasil uji variasi nilai *maximum of depth* algoritma *decision tree*

b. *Random forest* (RF)

Pada algoritma *random forest* dilakukan pencarian parameter terbaik dengan memvariasikan jumlah *maximum of depth* dan *number of tree*, dimana setiap perubahan nilai *maximum of depth* dan *number of tree* di bandingkan nilai metrik evaluasinya. Parameter awal yang digunakan dalam pengujian adalah rasio dataset 60:40 Hasil metrik evaluasi untuk setiap perubahan jumlah maksimal of depth dapat dilihat pada tabel 4.4.

Tabel 4.4 Perbandingan hasil uji variasi nilai *maximum of depth* algoritma *random forest* rasio 60:40


No	<i>Maximum of depth</i>	RMSE	MAE	SC
1.	1	89,333	76,603	0
2.	2	40,08	32,639	0,804
3.	3	15,019	11,31	0,972
4.	4	11,506	9,221	0,984
5.	5	11,159	8,575	0,985
6.	6	11,913	7,827	0,983
7.	7	11,715	7,601	0,983
8.	8	11,654	7,529	0,983

9.	9	11,646	7,518	0,983
10.	10	11,645	7,519	0,983
11.	11	11,645	7,519	0,983
12.	12	11,645	7,519	0,983

Berdasarkan hasil tabel 4.4 diatas diketahui bahwasanya terjadi penurunan nilai RMSE dan MAE seiring dengan meningkatnya nilai *maksimum of depth*, berbanding terbalik dengan nilai SC yang mengalami kenaikan.

Untuk mengambil mana parameter terbaik yang akan digunakan diambil nilai RMSE dan MAE terkecil dengan nilai SC tertinggi. Berdasarkan hasil tabel 4.3 diatas diambil nilai *maksimum of depth* sebesar 10 dengan nilai RMSE 11,645, nilai MAE 7,519 dan nilai SC 0,983. Hal ini dikarenakan setelah kenaikan nilai *maksimum of depth* lebih dari 6, tidak ada kenaikan nilai RMSE, MAE dan penurunan nilai SC. Dengan begitu dalam pengujian algoritma *random forest* selanjutnya diambil nilai *maksimum of depth* sebesar 10.

Berikut adalah hasil grafik perbandingan nilai *maksimum of depth* algoritma *random forest* dapat dilihat pada Gambar 4.3 dibawah.



Gambar 4.3 Grafik perbandingan hasil uji variasi nilai *maksimum of depth* algoritma *random forest*

Setelah didapatkan nilai *maksimum of depth* sebesar 10 untuk pengujian algoritma *random forest*, selanjutnya dilakukan pengujian variasi nilai *number of trees* untuk mendapatkan data perbandingan nilai RMSE, MAE dan SC. Seperti dalam pengujian nilai *maksimum of depth*, diambil nilai RMSE dan MAE terkecil dengan nilai SC tertinggi. Hasilnya dapat dilihat pada tabel 4.5 dibawah berikut.


Tabel 4.5 Perbandingan hasil uji variasi nilai *number of trees* algoritma *random forest*

No	<i>Number of trees</i>	RMSE	MAE	SC
1.	20	13,26	7,923	0,979
2.	40	12,146	7,681	0,982
3.	60	12,033	7,636	0,982
4.	80	11,856	7,598	0,983
5.	100	11,645	7,519	0,983
6.	120	11,473	7,458	0,984
7.	140	11,338	7,454	0,984
8.	160	11,327	7,455	0,984
9.	180	11,391	7,474	0,984
10.	200	11,467	7,454	0,984

Berdasarkan hasil tabel 4.5 diatas diketahui bahwasanya terjadi penurunan nilai RMSE dan MAE seiring dengan meningkatnya nilai *number of trees*, berbanding terbalik dengan nilai SC yang mengalami kenaikan.

Untuk mengambil mana parameter terbaik yang akan digunakan diambil nilai RMSE dan MAE terkecil dengan nilai SC tertinggi. Berdasarkan hasil tabel 4.5 diatas diambil nilai *number of trees* sebesar 160 dengan nilai RMSE 11,327, nilai MAE 7,455 dan nilai SC 0,984. Hal ini dikarenakan setelah kenaikan nilai *number of trees* lebih dari 160, terjadi kenaikan nilai RMSE dan MAE sedangkan nilai SC tetap. Dengan begitu dalam pengujian algoritma *random forest* selanjutnya diambil nilai *number of trees* sebesar 160.

Berikut adalah hasil grafik perbandingan nilai *number of trees* algoritma *random forest* dapat dilihat pada gambar 4.4 dibawah.



Gambar 4.4 Grafik perbandingan hasil uji variasi nilai *number of trees* algoritma *random forest*

4.2 Pembahasan


4.2.1 Cross Validation

Cross validation merupakan salah satu teknik dalam melakukan validasi model yang melibatkan pembagian data menjadi beberapa *subset* atau *fold*. Pada setiap iterasinya, satu *fold* digunakan sebagai data validasi, sementara *fold* yang lain menjadi data latih[37]. Dalam penelitian ini, digunakan *cross validation* dengan *K-fold 5*, yang berarti data dibagi menjadi 5 *subset* yang berbeda dan dilakukan 5 iterasi. Setiap iterasi menggunakan *subset* secara bergantian sebagai data uji dan subset lainnya sebagai data latih. Performa model dihitung menggunakan metrik evaluasi seperti MAE, RMSE, dan *R-squared*. Setelah 5 iterasi, performa model pada setiap *fold* diambil rata-ratanya untuk memperoleh performa model yang konsisten dan stabil. Metode *k-fold cross validation* ini memungkinkan pengujian validitas model prediksi dengan lebih akurat dan reliabel karena memperhitungkan variasi data pada setiap *fold*[38]. Selain itu, dengan menggunakan *k-fold 5*, jumlah data pelatihan yang digunakan lebih banyak, sehingga evaluasi model menjadi lebih akurat dan dapat dipercaya.

Hasil validasi model dari dua algoritma *machine learning* ini tidak menunjukkan perbedaan dengan hasil pengujian sebelumnya. Hal ini menegaskan bahwa model yang digunakan memiliki performa yang stabil dan dapat diandalkan dalam melakukan prediksi pada dataset yang lebih besar dan beragam. Hasil perbandingan cross validation dengan k-fold 5 untuk dua algoritma dapat dilihat pada tabel 4.6 dan Gambar 4.6 untuk TS serta tabel 4.7 dan Gambar 4.7 untuk YS.

Tabel 4.6 Hasil Perbandingan nilai metrik validasi pada variasi rasio untuk prediksi *tensile strength*

No	Algoritma	<i>Tensile Strength</i>								
		Rasio 60:40			Rasio 70:30			Rasio 80:20		
		RMSE	MAE	SC	RMSE	MAE	SC	RMSE	MAE	SC
1.	<i>Random forest</i>	36,567	25,826	0,578	36,822	27,425	0,547	39,406	28,791	0,542
2.	<i>Decision tree</i>	36,045	24,344	0,595	42,382	29,296	0,443	42,684	29,876	0,482




Gambar 4.5 Perbandingan performa algoritma *random forest* dan *decision tree* pada prediksi TS

Pada Gambar 4.5 grafik menunjukkan nilai RMSE, MAE dan SC pada prediksi TS (*tensile strength*) berdasarkan nilai aktual dan nilai prediksi dari data uji. Pada pengujian digunakan algoritma *decision tree* dan *random forest* dengan perbandingan rasio 60:40, 70:30 dan 80:20. Dari grafik diatas didapatkan rasio terbaik dalam prediksi TS sebesar 70:30 menggunakan algoritma *random forest*. Hal ini disebabkan nilai RMSE (*root meansquared error*) lebih kecil dari hasil pemodelan *random forest* yakni sebesar 36,822, kemudian diikuti dengan nilai MAE (*mean absolute error*) lebih kecil juga sebesar 27,425 serta memiliki nilai SC (*squared correlation*) tertinggi dari pada yang lain sebesar 0,547.

Tabel 4.7 Hasil Perbandingan nilai metrik validasi pada variasi rasio untuk prediksi *yield strength*

No	Algoritma	Yield Strength								
		Rasio 60:40			Rasio 70:30			Rasio 80:20		
		RMSE	MAE	SC	RMSE	MAE	SC	RMSE	MAE	SC
1.	<i>Random forest</i>	11,840	7,525	0,976	11,248	7,157	0,977	13,625	7,989	0,971
2.	<i>Decision tree</i>	14,276	7,056	0,967	13,364	7,017	0,969	15,780	8,043	0,960




Gambar 4.6 Perbandingan performa algoritma *random forest* dan *decision tree* pada prediksi YS

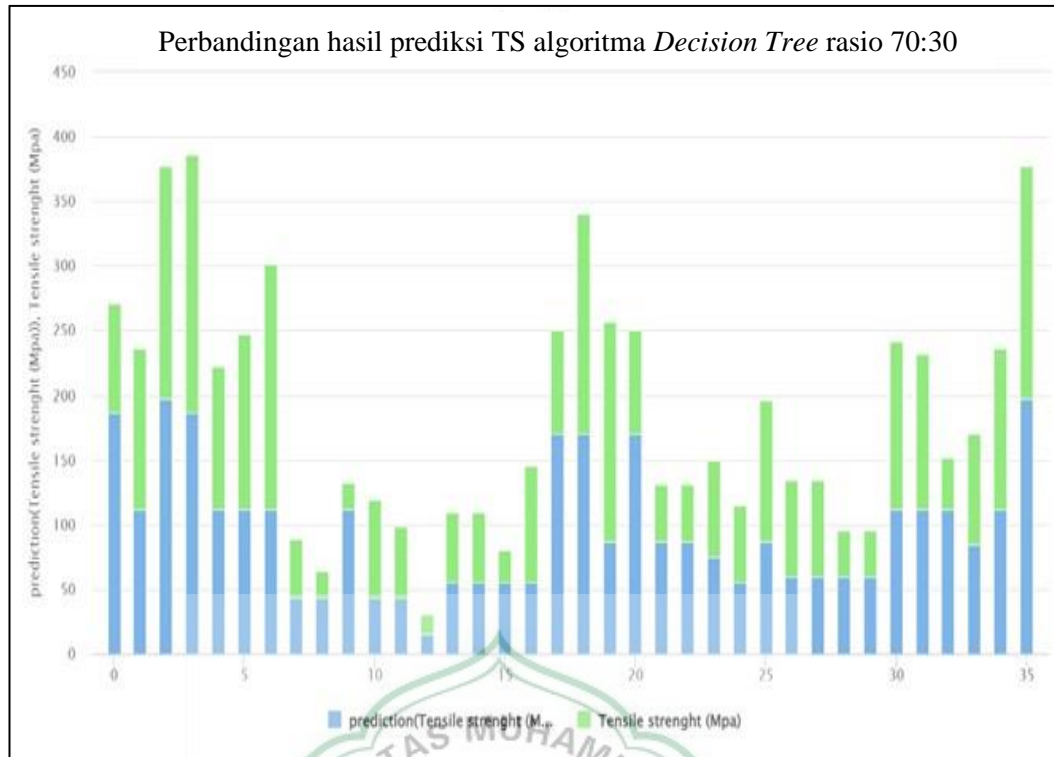
Pada Gambar 4.6 grafik menunjukkan nilai RMSE, MAE dan SC pada prediksi YS (*yield strength*) berdasarkan nilai aktual dan nilai prediksi dari data uji. Pada pengujian digunakan algoritma *decision tree* dan *random forest* dengan perbandingan rasio 60:40, 70:30 dan 80:20. Dari grafik diatas didapatkan rasio terbaik dalam prediksi YS sebesar 70:30 menggunakan algoritma *random forest*. Hal ini disebabkan nilai RMSE (*root meansquared error*) lebih kecil dari hasil rasio lain yakni sebesar 11,248, kemudian diikuti dengan nilai MAE (*mean absolute error*) lebih kecil juga sebesar 7,157 serta memiliki nilai SC (*squared correlation*) tertinggi dari pada yang lain sebesar 0,977.

4.2.2 Evaluasi Model

Evaluasi model bertujuan untuk menilai sejauh mana kualitas model yang dihasilkan dalam melakukan prediksi[36]. Berdasarkan hasil pemodelan dengan membandingkan dua algoritma, ditemukan bahwa algoritma random forest dengan perbandingan 70:30 menunjukkan performa yang lebih baik dalam memprediksi nilai *yield strength* dan *tensile strength* dibandingkan dengan algoritma *decision tree*. Hasil perbandingan prediksi kedua algoritma *machine learning* dalam memprediksi sifat mekanik aluminium dapat dilihat pada gambar 4.7 dan 4.8 untuk TS, serta gambar 4.9 dan 4.10 untuk YS.

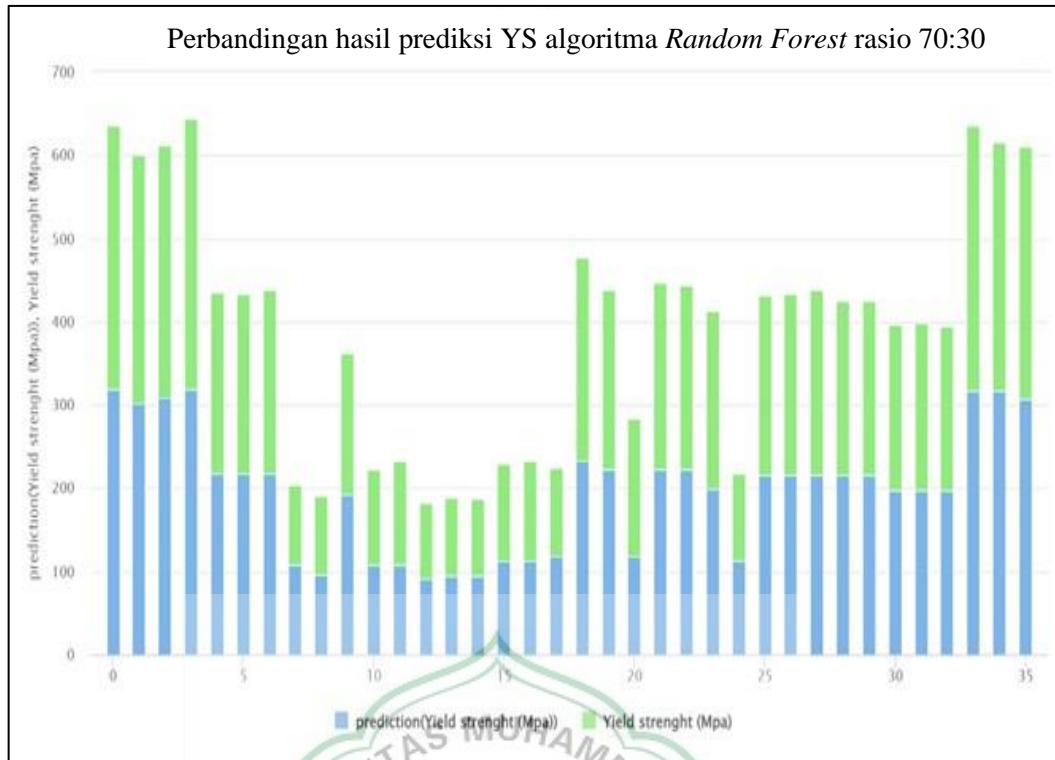


Gambar 4.7 Grafik perbandingan data prediksi nilai *tensile strength* dengan data aktual menggunakan algoritma *Random forest* rasio 70:30




Gambar 4.8 Grafik perbandingan data prediksi nilai *tensile strength* dengan data aktual menggunakan algoritma *Decision tree* rasio 70:30

Berdasarkan Gambar 4.7 dan 4.8 diatas, terlihat hasil prediksi *tensile strength* terbaik terdapat pada algoritma *random forest* dengan rasio 70:30. Hal ini disebabkan pada pemodelan *training* dan *testing* untuk mendapatkan nilai metrik RMSE, MAE dan SC terbaik, hasil yang didapatkan pada pemodelan algoritma *random forest* lebih baik daripada *decision tree*. Hasil penelitian ini selaras dengan hasil penelitian sebelumnya dimana algoritma *random forest* merupakan algoritma dengan kemampuan kinerja prediksi sifat mekanik material lebih baik daripada algoritma *decision tree*[36].



Gambar 4.9 Grafik perbandingan data prediksi nilai *yield strenght* dengan data aktual menggunakan algoritma *Random forest* rasio 70:30



Gambar 4.10 Grafik perbandingan data prediksi nilai *yield strenght* dengan data aktual menggunakan algoritma *Decision tree* rasio 70:30

Berdasarkan Gambar 4.9 dan 4.10 diatas, terlihat hasil prediksi *yield strength* terbaik terdapat pada algoritma *random forest* dengan rasio 70:30. Hal ini disebabkan pada pemodelan *training* dan *testing* untuk mendapatkan nilai metrik RMSE, MAE dan SC terbaik, hasil yang didapatkan pada pemodelan algoritma *random forest* lebih baik daripada *decision tree*. Hasil penelitian ini selaras dengan hasil penelitian sebelumnya dimana algoritma *random forest* merupakan algoritma dengan kemampuan kinerja prediksi sifat mekanik material lebih baik daripada algoritma *decision tree*[36].



BAB V

KESIMPULAN dan SARAN

5.1 Kesimpulan

Dari penelitian yang telah dilakukan mengenai prediksi sifat mekanik aluminium berdasarkan unsur kimia paduan menggunakan model *machine learning* dapat disimpulkan sebagai berikut:

1. *Heatmap correlation* mampu memberikan informasi hubungan korelasi antara unsur kimia paduan aluminium dengan sifat mekanik aluminium seperti *Yield strength* (YS) dan *Tensile strength* (TS).
2. Hasil prediksi nilai *yield strength* terbesar diperoleh dari hasil pengujian model algoritma *random forest* dengan parameter *maximum of depth* sebesar 10, *number of trees* sebesar 160 dan rasio perbandingan sebesar 70:30. Diikuti dengan nilai RMSE sebesar 11,248, MAE sebesar 7,157 dan SC sebesar 0,977.
3. Hasil prediksi nilai *tensile strength* terbesar diperoleh dari hasil pengujian model algoritma *random forest* dengan parameter *maximum of depth* sebesar 10, *number of trees* sebesar 160 dan rasio perbandingan sebesar 70:30. Diikuti dengan nilai RMSE sebesar 42,382, MAE sebesar 29,296 dan SC sebesar 0,443.

5.2 Saran

Untuk pemodelan *machine learning* dalam prediksi sifat mekanik material, ada beberapa bahasa pemrograman yang bisa dipertimbangkan selain *RapidMiner*. Beberapa bahasa yang populer dan kuat untuk mengembangkan model *machine learning* adalah *Python*, *R*, dan *Julia*.

Dalam memilih bahasa pemrograman, penting untuk mempertimbangkan beberapa faktor seperti ketersediaan *library machine learning*, kemudahan penggunaan, performa komputasi, serta dukungan dan komunitas yang aktif. *Python*, *R*, dan *Julia* semuanya merupakan pilihan yang baik untuk pemodelan *machine learning* dalam prediksi sifat mekanik material.

Daftar Pustaka

- [1] J. R. Davis, *Aluminium and Aluminium Alloy*. Ohio: ASM International, 1994.
- [2] D. Permatasari, Z. Zuhaimi, and A. Jannifar, "Analisa Sifat Mekanik Aluminium Alloy 6151 Setelah Mengalami Perlakuan Panas," *J. Mesin Sains Terap.*, vol. 4, no. 1, p. 1, 2020, doi: 10.30811/jmst.v4i1.1737.
- [3] S. Gunawan, P.H, "Uji Mekanik Material Struktur Aluminium Tangki Reaktor untuk Menentukan Keandalan Operasionalnya," *Semin. Nas. TEKNOKA_FT UHAMKA*, vol. 30, pp. 149–161, 2016, [Online]. Available:
www.uhamka.ac.id,%0Awww.uhamka.ac.id,%0Ajournal.uhamka.ac.id › [index.php](#) › [teknoka](#) › [article](#) › [download](#)%0A%0A
- [4] W. K. Smith, J., Xiong, W., Yan, W., Lin, S., Cheng, P., Kafka, O. L., ... & Liu, "Linking process, structure, property, and performance for metal-based additive manufacturing: computational approaches with experimental support.," *Comput. Mech.*, no. 57, pp. 583–610, 2016.
- [5] M. D, "Prediction of the Bilinear Stress-Strain Curve of Aluminum Alloys Using Artificial Intelligence and Big Data," *Metals (Basel)*, pp. 2–29, 2020.
- [6] A. Desmarita leni, Yuda perdana kusuma, Ruzita sumiati, Muchlisinalahuddin, "Perbandingan Alogaritma Machine Learning Untuk Prediksi Sifat Mekanik Pada Baja Paduan Rendah," *J. Rekayasa Mater. Manufaktur dan Energi*, vol. 2, no. 2, pp. 131–139, 2019.
- [7] A. Agrawal, P. D. Deshpande, A. Cecen, G. P. Basavarsu, A. N. Choudhary, and S. R. Kalidindi, "Exploration of data science techniques to predict fatigue strength of steel from composition and processing parameters," *Integr. Mater. Manuf. Innov.*, vol. 3, no. 1, pp. 90–108, 2014, doi: 10.1186/2193-9772-3-8.
- [8] S. Kendale, P. Kulkarni, A. D. Rosenberg, and J. Wang, "Supervised Machine-learning Predictive Analytics for Prediction of Postinduction Hypotension," *Anesthesiology*, vol. 129, no. 4, pp. 675–688, 2018, doi:

10.1097/ALN.0000000000002374.

- [9] dan S. S. Tata Surdia, *Pengetahuan Bahan Teknik*. Jakarta: PT. Praditiya Paramita, 2005.
- [10] Boydmets, “Everything You Need to Know About: Aluminum,” *blog.boydmets.com*, 2022. <https://blog.boydmets.com/everything-you-need-to-know-about-aluminum> (accessed May 23, 2023).
- [11] R. B. S. Majanasastra, “ANALISIS SIFAT MEKANIK DAN STRUKTUR MIKRO HASIL PROSES HYDROFORMING PADA MATERIAL TEMBAGA (Cu) C84800 DAN ALUMINIUM Al 6063,” vol. 4, no. 2, pp. 15–30.
- [12] D. Callister Jr, William, *Material Science and Engineering*, 3rd editio. New Jersey: Inc. Hoboken, 1994.
- [13] M. Kurek, “Fatigue prediction of aluminum alloys considering critical plane orientation under complex stress states,” *Materials (Basel)*., vol. 13, no. 17, 2020, doi: 10.3390/ma13173877.
- [14] D. A. A. Ritonga, “PENGARUH PENAMBAHAN Si PADA PADUAN Al – Si TERHADAP KEKUATAN IMPAK,” *Wahana Inov.*, vol. 7, no. 2, pp. 7–12, 2018.
- [15] Anonym, “Uji Tarik dan Hukum Hooke,” *pengujianlogam.wordpress.com*, 2018. <https://pengujianlogam.wordpress.com/2018/11/02/uji-tarik/> (accessed Jul. 14, 2023).
- [16] P. Song, Y., Chai, M., Han, Z., & Liu, “High-Temperature Tensile and Creep Behavior in a CrMoV Steel and Weld Metal. *Materials*,” vol. 15, no. 1, p. 109, 2021.
- [17] J. R. Hossain, U., Ghouse, S., Nai, K., & Jeffers, “Mechanical and morphological properties of additively manufactured SS316L and Ti6Al4V micro-struts as a function of build angle,” *Addit. Manuf.*, vol. 46, no. 102050, 2021.
- [18] Anonym, “Ini Bahan Body Mobil yang Paling Sering Digunakan, Mana yang Terbaik?,” *hyundai.com*, 2022.
- [19] M. F. Rochmat *et al.*, “Pengaruh Penambahan Unsur Magnesium Terhadap Sifat Mekanis,” *J. Tek. Mesin S-1*, vol. 10, no. 1, pp. 31–36, 2022.

- [20] Junaidi, "Pengaruh Perlakuan Panas Pada Aluminium 5083 Terhadap Uji Impact," *Semnastek - Uisu 2022*, pp. 23–29, 2022.
- [21] D. Banabic, "Effect of the Mechanical Parameters Used as Input Data in the Yield Criteria on the Accuracy of the Finite Element Simulation of Sheet Metal Forming Processes," *researchgate.net*, 2013.
https://www.researchgate.net/figure/Stress-strain-curves-of-AA6016-T4-aluminium-alloy-sheet_fig1_272637629 (accessed Jul. 14, 2023).
- [22] Makeitfrom, "1050-H112 Aluminum," *www.makeitfrom.com*.
<https://www.makeitfrom.com/material-properties/1050-H112-Aluminum> (accessed May 24, 2023).
- [23] Z.-H. ZHOU, *Machine learning*. Springer Nature, 2021.
- [24] S. M. Rezkia, "Begini Konsep dan Cara Kerja Algoritma Machine Learning," *dqlab.id*, 2021. <https://dqlab.id/begini-konsep-dan-cara-kerja-algoritma-machine-learning> (accessed May 24, 2023).
- [25] S. S. Han, J., Kamber, M., Melton, J., Buxton, S., Teorey, T. J., Lightstone, G. C. Nadeau, T. P., Celko, J., Witten, I., Frank, E., Simson, G. C., Witt, and A. Schiller, J., Voisard, A., Halpin, T., Evans, K., Hallock, P., Maclean, B. Ceri, S., ... Voisard, *Data Mining: Concepts and Techniques*, 2nd ed., V. Diane Cerra, 2006.
- [26] P. PATEL, Harsh H.; PRAJAPATI, "Study and analysis of decision tree based classification algorithms," *Int. J. Comput. Sci. Eng.*, vol. 6, no. 10, pp. 74–78, 2018.
- [27] Suyanto, *Artificial Intelligence: Searching, Reasoning, Planning and Learning (2nd ed.)*. Bandung: Informatika.
- [28] Iykra, "Mengenal Decision Tree dan Manfaatnya," *medium.com*, 2018.
<https://medium.com/iykra/mengenal-decision-tree-dan-manfaatnya-b98cf3cf6a8d> (accessed May 14, 2023).
- [29] F. Livingston, "Implementation of Breiman's random forest machine learning algorithm," *ECE591Q Mach. Learn. J. Pap.*, pp. 1–13.
- [30] C. Team, "Random Forest," *corporatefinanceinstitute.com*, 2023.
<https://corporatefinanceinstitute.com/resources/data-science/random-forest/> (accessed May 24, 2023).

- [31] A. Liparas, D., HaCohen-Kerner, Y., Moutzidou, A., Vrochidis, S. and I. Kompatsiaris, "News articles classification using random forests and weighted multimodal features," *In Information Retrieval Facility Conference*. Cham, pp. 63–67.
- [32] D. A. C, D. A. Baskoro, L. Ambarwati, and I. W. S. Wicaksana, *Belajar Data Mining dengan RapidMiner*. Jakarta, 2013.
- [33] A. Rumor, L., & Andrade-Campos, "On the need for material model databases: A state-of-the-art review," *Adv. Mech. Eng.*, vol. 14, no. 10, 2022.
- [34] I. J. R. T. E. JOURNAL, "Volume-9 issue-3, September 2020," *Int. J. Recent Technol. Eng.*, vol. 9, no. 3, 2022, [Online]. Available: <https://www.ijrte.org/download/volume-9-issue-3/>.
- [35] C. A. ARLOT S, "A survey of cross-validation procedures for model selection," *Stat Surv*, vol. 4, pp. 40–79, 2010.
- [36] D. Leni, "Pemilihan Algoritma Machine Learning Yang Optimal Untuk Prediksi Sifat Mekanik Aluminium," *J. Engine Energi, Manufaktur, dan Mater.*, vol. 7, no. 1, pp. 35–44, 2023.
- [37] T. G. Prasetyo, A. B., & Laksana, "Optimasi Algoritma K-Nearest Neighbors dengan Teknik Cross Validation Dengan Streamlit (Studi Data: Penyakit Diabetes)," *n Streamlit (Studi Data Penyakit Diabetes)*. *J. Appl. Informatics Comput.*, vol. 6, no. 2, p. 194, 2022, [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [38] A. T. Intan, I., Ghani, S. A. D., Nurdin, & Koswara and C., "Performance Analysis of Weather Forecasting using Machine Learning Algorithms," *J. Pekommas*, vol. 6, no. 2, pp. 1–8, 2021, [Online]. Available: <https://doi.org/10.30818/jpkm.2021.2060221%0D>

Lampiran

Lampiran 1. Database aluminium alloys dari website MakeItFrom.com

No	Spesimen	Mg	Zn	Ti	Cu	Mn	Cr	Fe	Si	Al	Tensile strength (Mpa)	Yield strength (Mpa)
1	5454 O	1,4	0,26	0,2	0,1	0,5	0,05	0,4	0,25	96,84	85	317
2	AA 5083	1,4	0,25	0,15	0,1	0,4	0,05	0,4	0,4	96,85	124	299
3	5454 H32	1,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	96,85	180	305
4	5454 H24	1,4	0,26	0,2	0,1	0,5	0,05	0,4	0,25	96,84	200	325
5	5050 H32	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	110	217
6	5050 H34	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	135	215
7	5050 H18	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	190	220
8	1050A O	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	45	95
9	1050A H111	0,05	0,07	0,04	0,05	0,05	0	0,4	0,25	99,09	20	95
10	5050 O	1,1	0,22	0	0,2	0,1	0,1	0,7	0,4	97,18	20	170
11	1050A H24	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	75	115
12	1050A H22	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	55	125
13	1080A O	0,02	0,05	0	0,03	0,02	0	0,15	0,15	99,58	15	90
14	1080A H12	0,02	0,06	0	0,03	0,02	0	0,15	0,15	99,57	55	96
15	1080A H16	0,02	0,06	0	0,03	0,02	0	0,15	0,15	99,57	55	93
16	1200 O	0	0,1	0,05	0,05	0,05	0	1	1	97,75	25	116
17	1200 h24	0	0,1	0,06	0,05	0,05	0	1	1	97,74	90	121
18	3003 h22	0	0,1	0	0,05	1	0	0,7	0,6	97,55	80	105
19	3004 H14	0,8	0,25	0	0,25	1	0	0,7	0,3	96,7	170	245
20	3004 H15	0,2	0,25	0	0,3	1	0,1	0,7	0,6	96,85	170	215
21	3003 h24	0	0,1	0	0,05	1	0	0,7	0,6	97,55	80	165
22	3005 h24	0,2	0,25	0	0,3	1	0,1	0,7	0,6	96,85	45	225
23	3005 h19	0,2	0,25	0	0,3	1	0,1	0,7	0,6	96,85	45	221
24	3103 h22	0,3	0,21	0	0	0,09	0	0,7	0,5	98,2	75	213
25	1200 h111	0	0,1	0,05	0,05	0,05	0	1	1	97,75	60	105
26	3103 h24	0,3	0,2	0	0,1	0,9	0,1	0,7	0,5	97,2	110	215
27	3103A H22	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	75	219
28	3103 H24	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	75	224
29	3103A H19	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	35	209
30	3103A O	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	35	209
31	3105 H14	0,2	0,4	0	0,3	0,3	0,2	0,7	0,6	97,3	130	199
32	3105 H24	0,2	0,4	0	0,3	0,3	0,2	0,7	0,6	97,3	120	200

33	3105 O	0,2	0,4	0	0,3	0,3	0,2	0,7	0,6	97,3	40	198
34	5454A O	1,4	0,25	0,25	0,11	0,5	0,05	0,4	0,25	96,79	85	319
35	AA 5083 O	1,4	0,25	0,15	0,1	0,4	0,05	0,4	0,49	96,76	124	298
36	5454 HA32	1,4	0,25	0,2	0,1	0,5	0,05	0,4	0,2	96,9	180	304
37	5454 HA24	1,4	0,24	0,2	0,1	0,5	0,05	0,4	0,25	96,86	200	323
38	5050 HA32	1,1	0,25	0,01	0,2	0,1	0,1	0,7	0,4	97,14	110	219
39	5050 HA34	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	135	213
40	5050 HA18	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	190	222
41	1050A OH	0,05	0,07	0,035	0,05	0,05	0	0,4	0,25	99,095	45	90
42	1050A H11	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	20	94
43	5050 OA	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	20	172
44	1050A A24	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	75	117
45	1050A H21	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	55	128
46	1080A HO	0,02	0,06	0	0,03	0,02	0	0,15	0,15	99,57	15	92
47	1080A H13	0,02	0,06	0	0,03	0,02	0	0,15	0,15	99,57	55	96
48	1080 H16	0,02	0,06	0	0,03	0,02	0	0,15	0,15	99,57	55	93
49	1200 O12	0	0,1	0,05	0,05	0,05	0	1	1	97,75	25	115
50	1200A H24	0	0,1	0,05	0,05	0,05	0	1	1	97,75	90	123
51	3003A h25	0	0,2	0	0,06	1	0	0,7	0,6	97,44	80	114
52	3003A h22	0	0,1	0	0,05	1	0	0,7	0,6	97,55	170	108
53	3004A H14	0,8	0,3	0	0,3	1	0	0,7	0,3	96,6	170	255
54	3004A H11	0,2	0,25	0	0,3	1	0,1	0,7	0,6	96,85	80	215
55	3003A h24	0	0,1	0	0,05	1	0	0,7	0,6	97,55	45	165
56	3005A h21	0,2	0,25	0	0,3	1	0,1	0,7	0,6	96,85	45	225
57	3005A h16	0,2	0,25	0	0,3	1	0,1	0,7	0,6	96,85	75	225
58	3103A h22	0,3	0,2	0	0	0,09	0	0,7	0,5	98,21	60	213
59	1200A h112	0	0,1	0,045	0,05	0,04	0	1	1	97,765	110	102
60	1200A h111	0	0,1	0,05	0,05	0,05	0	1	1	97,75	75	107
61	3103A h24	0,3	0,2	0	0,1	0,9	0,1	0,7	0,5	97,2	75	218
62	3103AA H22	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	35	219
63	3103A H24	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	35	223
64	3103A AH19	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	130	209
65	3103A O12	0,3	0,2	0	0,1	0,7	0,1	0,7	0,5	97,4	120	208

66	3105A H14	0,2	0,4	0	0,5	0,4	0,2	0,7	0,6	97	40	200
67	3105A H24	0,2	0,5	0	0,3	0,3	0,2	0,7	0,6	97,2	120	208
68	3105A O	0,2	0,4	0	0,3	0,3	0,2	0,7	0,6	97,3	40	198
69	3105 H19	0,2	0,4	0	0,3	0,3	0,2	0,7	0,6	97,3	190	187
70	5005 H14	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	120	211
71	5005 H24	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	110	209
72	5005 H19	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	185	205
73	5005 O	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	35	212
74	5049 O	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	80	330
75	5049 H111	1,6	0,28	0,1	0,1	0,5	0,3	0,5	0,4	96,22	80	345
76	5049 H22	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	130	332
77	5049 H32	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	130	327
78	5049 H28	1,6	0,2	0,1	0,1	0,5	0,25	0,4	0,4	96,45	160	335
79	5049 H24	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	160	343
80	5049 H34	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	85	329
81	5154 O	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	85	375
82	5154A H111	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	180	367
83	5154 H22	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	180	355
84	5154A H32	2,4	0,2	0,2	0,1	0,5	0,25	0,5	0,5	95,35	200	335
85	5154 H32	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	200	375
86	5154 H24	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	190	355
87	5154A H34	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	220	357
88	5454 H12	2,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	95,85	230	335
89	5454 H14	2,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	95,85	220	325
90	5454 H26	2,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	95,85	230	345
91	3105A H19	0,2	0,4	0	0,3	0,3	0,2	0,7	0,6	97,3	190	189
92	5005A H14	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	120	213
93	5005A H24	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	110	207
94	5005A H19	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	185	208
95	5005 O11	0,5	0,25	0	0,2	0,2	0,1	0,7	0,3	97,75	35	214
96	5049 O11	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	80	332
97	5049A H111	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	80	343
98	5049A H22	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	130	336
99	5049A H32	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	130	325
100	5049A H24	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	160	340

101	5049A H34	1,6	0,2	0,1	0,1	0,5	0,3	0,5	0,4	96,3	160	324
102	5154 011	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	85	370
103	5154A H11	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	85	361
104	5154 H21	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	180	352
105	5154 H34	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	180	370
106	5154 H22	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	200	352
107	5154A H32	3,1	0,2	0,2	0,1	0,5	0,25	0,5	0,5	94,65	200	352
108	5454 H15	2,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	95,85	190	338
109	5454 H11	2,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	95,85	220	333
110	5454 H24	2,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	95,85	230	340
111	5454 O34	1,4	0,26	0,2	0,1	0,5	0,05	0,4	0,25	96,84	230	316
112	AA 5082	1,4	0,25	0,15	0,1	0,4	0,05	0,4	0,4	96,85	220	300
113	5454 H34	1,4	0,25	0,2	0,1	0,5	0,05	0,4	0,25	96,85	230	303
114	5454 H32	1,4	0,26	0,2	0,1	0,5	0,05	0,4	0,25	96,84	230	323
115	5050 H24	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	85	218
116	5050 H36	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	90	212
117	5050 H14	1,1	0,25	0	0,2	0,1	0,1	0,7	0,4	97,15	96	222
118	1050A O22	0,05	0,07	0,05	0,05	0,05	0	0,4	0,25	99,08	35	93
119	1050A H	0,05	0,07	0,04	0,05	0,05	0	0,4	0,25	99,09	45	95
120	5050 O11	1,1	0,22	0	0,2	0,1	0,1	0,7	0,4	97,18	70	173

